

SVEUČILIŠTE U ZAGREBU
FAKULTET STROJARSTVA I BRODOGRADNJE

DIPLOMSKI RAD

Marko Budimir
0035172216

Zagreb, 2015.

SVEUČILIŠTE U ZAGREBU
FAKULTET STROJARSTVA I BRODOGRADNJE

DIPLOMSKI RAD

Voditelj rada:

Prof.dr.sc Biserka Runje

Student:

Marko Budimir

0035172216

Zagreb, 2015.

Izjavljujem da sam ovaj rad radio samostalno, služeći se znanjem stečenim tijekom studija i koristeći navedenu literaturu.

Ovom prilikom bih želio zahvaliti:

Voditelju rada Prof. dr.sc. Biserki Runje i Dr. sc. Gorana Baršić, dipl. ing. na stručnim savjetima i pomoći tijekom izrade diplomskog rada.

Posebno bih želio zahvaliti svojoj obitelji na potpori i pomoći kako tijekom izrade ovog rada, tako i tijekom cijelog studija.

Također zahvaljujem poduzeću Štefan d.o.o. i svojim kolegama i prijateljima na potpori i pomoći tijekom pisanja ovog rada.



SVEUČILIŠTE U ZAGREBU
FAKULTET STROJARSTVA I BRODOGRADNJE



Središnje povjerenstvo za završne i diplomske ispite
Povjerenstvo za diplomske ispite studija strojarstva za smjerove:
proizvodno inženjerstvo, računalno inženjerstvo, industrijsko inženjerstvo i menadžment, inženjerstvo
materijala i mehatronika i robotika

Sveučilište u Zagrebu Fakultet strojarstva i brodogradnje	
Datum	Prilog
Klasa:	
Ur.broj:	

DIPLOMSKI ZADATAK

Student: **MARKO BUDIMIR**

Mat. br.: 0035172216

Naslov rada na
hrvatskom jeziku:

**PRIMJENA ALATA KONTROLE KVALITETE U PRAĆENJU
PROCESA PROIZVODNJE NAREZNOG PRSTENA**

Naslov rada na
engleskom jeziku:

**APPLICATION OF QUALITY CONTROL TOOLS IN
MONITORING CUTTING RING PRODUCTION PROCESS**

Opis zadatka:

1. Opisati koncepte i alate kontrole kvalitete. Detaljno prikazati teorijske postavke kontrolnih karata za mjerljive karakteristike i procjene sposobnosti procesa.
2. Na realnom proizvodu definirati karakteristične značajke. Definirati veličine uzoraka i dinamiku uzorkovanja u skladu s karakteristikama proizvodnog procesa.
3. $\bar{x} - R$ kontrolnom kartom pratiti varijacije procesa u vremenu. Procijeniti sposobnost promatranog proizvodnog procesa te predložiti eventualna poboljšanja.

Zadatak zadan:

7. svibnja 2015.

Zadatak zadao:

Prof. dr. sc. Biserka Ružje

Rok predaje rada:

9. srpnja 2015.

Predviđeni datum obrane:

15., 16. i 17. srpnja 2015.

Predsjednik Povjerenstva:

Prof. dr. sc. Franjo Čajner

SADRŽAJ

SADRŽAJ	I
POPIS SLIKA.....	III
POPIS TABLICA.....	V
POPIS TEHNIČKE DOKUMENTACIJE	VI
POPIS OZNAKA	VII
SAŽETAK	VIII
SUMMARY	IX
1. UVOD	1
2. ŠTO JE KONTROLNA KARTA?	2
3. VRSTE KONTROLNIH KARATA	5
3.1. Kontrolne karte za mjerljive karakteristike	5
3.1.1 \bar{x} -R karta	5
3.1.2 \bar{x} -s karta	7
3.1.3 x - MR karta	8
3.2. Kontrolne karte za atributivne karakteristike	8
3.2.1 p -karta	8
3.2.2 np - karta	9
3.2.3 u -karta	9
3.2.4 c -karta	10
4. PROCJENJIVANJE SPOSOBNOSTI PROCESA.....	11
4.1. Procjena sposobnosti procesa s podacima koji se rasipaju po normalnoj razdiobi.....	11
4.2. Procjena sposobnosti procesa s podacima koji se ne rasipaju po normalnoj razdiobi.....	12
4.2.1 Analiza sposobnosti procesa sa ne-normalnom razdiobom podataka. 12	
5. INDEKSI SPOSOBNOSTI PROCESA	14
5.1. Potencijalna sposobnost C_p	14
5.2. Omjer sposobnosti C_r	16
5.3. Donja i gornja potencijalna sposobnost C_{pL} i C_{pU}	16
5.4. Faktor korekcije necentriranosti k	17
5.5. Demonstrirana izvrsnost C_{pk}	17
5.6. Stvarna sposobnost procesa P_p	18

5.7.	Preliminarna sposobnost procesa	20
5.8.	Sposobnost u kratkom vremenskom razdoblju	21
5.9.	Potencijalna sposobnost stroja C_{pm}	21
6.	EKSPERIMENTALAN DIO	22
6.1.	O poduzeću	22
6.2.	Predmet mjerenja	23
6.2.1	Ukratko o narezanim prstenovima	23
6.2.2	Narezni prsten pdr12LS.....	24
6.3.	Sredstvo mjerenja.....	27
7.	REZULTATI	29
7.1.	\bar{x} - R kontrolne karte	30
7.2.	Sposobnost proizvodnog procesa	42
8.	ZAKLJUČAK	51
	LITERATURA.....	52
	PRILOZI	53

POPIS SLIKA

Slika 1. Usporedni prikaz razdiobe aritmetičkih sredina.....	3
Slika 2. Algoritam za izbor prikladne kontrolne karte[2]	5
Slika 3. \bar{x} - R karta [3]	6
Slika 4. Prikaz razdiobe za različite potencijalne sposobnosti procesa[2].....	15
Slika 5. Razdioba s jednom granicom specifikacije[2].....	17
Slika 6. Razdioba pomaknutog procesa[2].....	18
Slika 7. Kontrolna karta proizvodnog procesa koji je pod kontrolom [2].....	19
Slika 8. Kontrolna karta proizvodnog procesa koji nije pod kontrolom [2]	19
Slika 9. Procjena sposobnosti procesa pod kontrolom [2].....	20
Slika 10. Procjena sposobnosti procesa koji nije pod kontrolom [2].....	20
Slika 11. Logo tvrtke Štefan d.o.o.	22
Slika 12. Logo njemačke tvrtke Volz GmbH.....	22
Slika 13. Logo njemačke tvrtke Focke GmbH.....	22
Slika 14. Poslovni objekt i proizvodni pogon tvrtke Štefan d.o.o.	22
Slika 15. Rastavljeni sklop nareznog prstena	23
Slika 16. Detaljni prikaz sklopa nareznog prstena	23
Slika 17. Predmet mjerenja.....	24
Slika 18. CAD model predmeta mjerenja	24
Slika 19. Nacrt s mjerenim veličinama koje sadrže tolerancije mjera.....	26
Slika 20. Nacrt s nazivima mjerenih veličina	26
Slika 21. Mjerno sredstvo.....	27
Slika 22. Formpak-programski paket za obradu podataka.....	27
Slika 23. Obrađeni i kotirani nacrt predmeta mjerenja	28
Slika 24. \bar{x} - R kontrolna karta za odrez.....	30
Slika 25. \bar{x} - R kontrolna karta za odrez nakon korigiranih podataka.....	31
Slika 26. \bar{x} - R kontrolna karta za vanjski kut.....	31
Slika 27. \bar{x} - R kontrolna karta za vanjski kut nakon korigiranih podataka	32
Slika 28. \bar{x} - R kontrolna karta za unutarnji kut	33
Slika 29. \bar{x} - R kontrolna karta za unutarnji kut nakon korigiranih podataka	34
Slika 30. \bar{x} - R kontrolna karta za vanjski radijus	35

Slika 31. \bar{x} - R kontrolna karta za vanjski radijus nakon korigiranih podataka	36
Slika 32. \bar{x} - R kontrolna karta za unutarnji radijus	36
Slika 33. \bar{x} - R kontrolna karta za unutarnji radijus nakon korigiranih podataka.....	37
Slika 34. \bar{x} - R kontrolna karta za vanjsku dužinu	38
Slika 35. \bar{x} - R kontrolna karta za vanjsku dužinu nakon korigiranih podataka	38
Slika 36. \bar{x} - R kontrolna karta za srednju dužinu	39
Slika 37. \bar{x} - R kontrolna karta za srednju dužinu nakon korigiranih podataka.....	40
Slika 38. \bar{x} - R kontrolna karta za unutarnju dužinu	40
Slika 39. \bar{x} - R kontrolna karta za unutarnju dužinu nakon korigiranih podataka	41
Slika 40. Procjena sposobnosti procesa za odrez	42
Slika 41. Procjena sposobnosti procesa za vanjski kut.....	43
Slika 42. Procjena sposobnosti procesa za unutarnji kut.....	43
Slika 43. Procjena sposobnosti procesa za vanjski radijus	44
Slika 44. Procjena sposobnosti procesa za unutarnji radijus	45
Slika 45. Procjena sposobnosti procesa nakon transformacije podataka	46
Slika 46. Procjena sposobnosti procesa za vanjsku dužinu	47
Slika 47. Procjena sposobnosti procesa za srednju dužinu	48
Slika 48. Procjena sposobnosti procesa uz Weibullov model	48
Slika 49. Procjena sposobnosti procesa za unutarnju dužinu	49

POPIS TABLICA

Tablica 1. Koeficijenti kontrolnih granica za \bar{x} - R kartu[2]	6
Tablica 2. Koeficijenti kontrolnih granica za \bar{x} - s kartu[2]	8
Tablica 3. Tablica mjerenih veličina	25
Tablica 4. Dio tablice s mjerenjima	29

POPIS TEHNIČKE DOKUMENTACIJE

150417-pdr12LS-2	Obrađeni i kotirani nacrt predmeta mjerenja
Mjerenje V12	Popis mjerenih veličina za praktičan dio rada

POPIS OZNAKA

Oznaka	Jedinica	Opis
x_0		Sredina osnovnog skupa
\bar{x}_i		Aritmetička sredina i -tog skupa
k		Broj uzoraka, faktor korigiranosti procesa kod indeksa procjene sposobnosti
n		Veličina uzoraka
GKG (eng. USL)		Gornja kontrolna granica
DKG (eng. LSL)		Donja kontrolna granica
σ		Standardna devijacija, standardno odstupanje, mjera kvalitete procesa
R		Raspon; razlika između najveće i najmanje vrijednosti rezultata
s		Procijenjeno standardno odstupanje
p		Broj loših komada po uzorku
\bar{u}		Prosječan broj grašaka na jedinicu proizvoda
\bar{c}		Prosječan broj grešaka po uzorku
T		Tolerancijsko područje
C_p		Potencijalna sposobnost procesa
C_r		Omjer sposobnosti procesa
C_{pU}		Gornja potencijalna sposobnost (Upper potential capability)
C_{pL}		Donja potencijalna sposobnost i (Lower potential capability)
C_{pk}		Demonstrirana izvrsnost
P_p		Stvarna sposobnost procesa
C_{pm}		Potencijalna sposobnost stroja

SAŽETAK

U radu su opisani koncepti i alati kontrole kvalitete. Detaljno prikazane teorijske postavke kontrolnih karata za mjerljive karakteristike i procjene sposobnosti procesa.

U radu se naglašava značaj primjene alata kontrole kvalitete u praćenju i postupcima poboljšavanja kvalitete procesa proizvodnje nareznog prstena koji se proizvodi u stvarnom proizvodnom pogonu tvrtke Štefan d.o.o.

Na realnom proizvodu definirane su karakteristične značajke. Definirana je veličina uzorka i dinamika uzorkovanja u skladu s karakteristikama proizvodnog procesa.

Mjerenja su se odvijala u tvrtci Štefan d.o.o. na predmetu mjerenja koji se proizvodi u proizvodnom pogonu tvrtke, koja do sada nije koristila kontrolne karte.

\bar{x} - R kontrolnom kartom su praćene varijacije procesa u vremenu, te je na temelju toga procijenjena sposobnost promatranog proizvodnog procesa te su predložena eventualna poboljšanja za postojeći proizvodni proces.

Ključne riječi: kontrolne karte, sposobnost procesa, kontrola kvalitete

SUMMARY

The paper describes the concepts and tools of quality control. Theoretical assumptions of control charts for measurable characteristics and capability analysis of the process are shown in detail.

The paper points out the importance of applying the tools of quality control procedures in monitoring and improving the quality of the production process of the cutting ring, which is produced in a real production facility of the company Štefan d.o.o.

The characteristic features are defined on a real product. Sample size and dynamics of sampling are defined in accordance with the characteristics of the production process.

The measurements were conducted at the company Štefan d.o.o. on the object of measurement which is produced in the production facility of the company, which until now has not used control charts.

\bar{x} - R control charts are accompanied by variations in process at the time, and on this basis capability analysis of the observed production process was made and the improvements were proposed for the existing production process.

Key words: control charts, capability analysis, quality control

1. UVOD

Kontrolna karta je nedvojbeno najznačajniji alat kontrole kvalitete i temeljni pokazatelj mogućnosti poboljšavanja kvalitete procesa, odnosno proizvoda. Tehnika kontrolnih karata sastoji se od uzimanja većeg broja malih uzoraka iz procesa. Uzorci se uzimaju, ako je to primjenljivo, u slučajnim obilascima. Važno je naznačiti da se kontrolom kartom prate varijacije procesa u vremenu. To znači da uzorci uvijek moraju biti zadnje proizvedene jedinice.

Većina kontrolnih karata koje se danas primjenjuju u aktivnostima kontrole kvalitete nastala je u drugoj polovici dvadesetih godina prošlog stoljeća u laboratorijima Bell Telephone Company. Autor tih karata bio je dr. Walter A. Shewhart, koji je svoja istraživanja i saznanja vezana uz mogućnost primjene kontrolnih karata objavio 1931. god. u svojoj knjizi "Economic Control of Quality of Manufactured Product". Te karte se u nepromijenjenom obliku koriste danas i predstavljaju temelj statističkog praćenja procesa. Od Shewarta do dan danas nije objavljena niti jedna knjiga iz područja kontrole kvalitete u kojoj značajno mjesto ne zauzimaju i kontrolne karte.

Primjena kontrolnih karata zadnjih 20 godina je značajno porasla. Uzrok tome je otvorna mogućnost integriranja SPC softvera u proizvodne procese, te sve šira primjena u postupcima procjenjivanja i dokazivanja sposobnosti procesa. Kontrolne karte zauzimaju značajno mjesto u metodologiji šest sigma, statističkim tolerancijama i drugo. S toga se može reći da se svi moderni pristupi kontroli i poboljšavanju kvalitete u prvom redu oslanjaju na kontrolne karte. Kontrolne karte su bez ikakve sumnje najznačajniji alat kontrole i poboljšavanja kvalitete.[1]

2. ŠTO JE KONTROLNA KARTA?

Kontrolna karte je u prvom redu slika procesa. Kontrolna karta prikazuje kako se mjerni podaci (značajka procesa, proizvoda i sl.) kreću u vremenu i što treba poduzimati u cilju poboljšanja kvalitete.

Tehnika kontrolnih karata sastoji se od uzimanja većeg broja malih uzoraka iz procesa. Uzorci se uzimaju, ako je to primjenljivo, u slučajnim obilascima. Važno je naznačiti da se kontrolnom kartom prate varijacije procesa u vremenu. To znači da uzorci uvijek moraju biti zadnje proizvedene jedinice.

Kontrolne karte dijele se u dvije temeljne skupine:

1. kontrolne karte za mjerljive karakteristike: \bar{x} - R karta, \bar{x} - s karta, \bar{x} - MR karta, $CuSum$ karta, $EWMA$ karta. Matematska podloga ovih karata je normalna raspodjela.
2. kontrolne karte za atributivne karakteristike: p karta, $n-p$ karta, c karta, u karta. Matematska podloga ovih karata je binomna i Poissonova raspodjela.

Osnova statističke metode u kontroli kvalitete je uzimanje većeg broja malih uzoraka iz osnovnog skupa. Veza između osnovnog skupa i jednog uzorka vrlo je labava, ali s većim brojem uzoraka posve je određena.[1]

Aritmetička sredina:


$$x_0 \cong \bar{\bar{x}} = \frac{\bar{x}_1 + \bar{x}_2 + \bar{x}_3 + \dots + \bar{x}_k}{k}$$

x_0 – sredina osnovnog skupa

\bar{x}_i – aritmetička sredina i -tog skupa

k – broj uzoraka

n – veličina uzoraka



Slika 1. Usporedni prikaz razdiobe aritmetičkih sredina uzorka i razdiobe osnovnog skupa (proces)[2]

Na svakoj kontrolnoj karti treba odrediti kontrolne granice i središnju liniju.

Kontrolne granice su:

- donja kontrolna granica DKG (lower control limit LCL)
- gornja kontrolna granica GKG (upper control limit UCL)

Kontrolne granice su statističke granice i nisu povezane s granicama specifikacije (zahtjeva). Kontrolne granice se postavljaju (računaju) na granice rasipanja ($\pm 3\sigma$) statističkog parametra (\bar{x} , R , s i drugo) koji se prati kontrolnom kartom (računa iz uzoraka). Pored kontrolnih granica mogu se koristiti i tzv. granice upozorenja (postavljaju se na $\pm 2\sigma$ ili $\pm 1\sigma$).

Pri čemu vrijede veze:

- između σ_0 i $\sigma_{\bar{x}}$ - $\sigma_{\bar{x}} = \frac{\sigma_0}{\sqrt{n}}$
- između \bar{R} i σ_0 - $\bar{R} = \frac{R_1 + R_2 + R_3 + \dots + R_k}{k}$; $\bar{R} = d_2 \sigma_0$; $d_2 = f(n)$
- između $\bar{\sigma}$ i σ_0 - $\bar{\sigma} = \frac{\sigma_1 + \sigma_2 + \sigma_3 + \dots + \sigma_k}{k}$; $\bar{\sigma} = c_2 \sigma_0$; $c_2 = f(n)$
- između σ_σ i σ_0 - $\sigma_\sigma = a_2 \sigma_0$; $a_2 = f(n)$

Podatak izvan kontrolne granice (iznad *GKG* ili ispod *DKG*) pokazuje da se u procesu, statistički promatrano, dogodio ne slučajan već značajan uzrok varijacije (odstupanja). Najefikasniji postupak poboljšavanja kvalitete praćenog procesa je promptno otkrivanje uzroka značajnih varijacija i provođenje odgovarajućih popravnih radnji. Kada nema podataka izvan kontrolnih granica onda se koristi termin "proces je pod kontrolom". Termin pod kontrolom je statistički termin kojim se pokazuje da proces varira samo pod utjecajem slučajnih, procesu svojstvenih, utjecaja. Za proces koji je pod kontrolom često se koristi i termin stabilan proces. Kada su podaci izvan kontrolnih granica to nipošto ne znači da proces daje nesukladne jedinice (proizvode).

Kontrolne karte se mogu i trebaju primjenjivati kako za procese koji nužno daju nesukladne proizvode ($C_p < 1$), tako i za sposobne procese ($C_p > 1$). U slučaju određivanja (računanja) kontrolnih granica za proces za koji nemamo prethodnih saznanja (nepoznate varijacije procesa) potrebno je provesti korekciju granica u slučaju pojave podataka izvan kontrolnih granica. Korekcija (ponovno računanje granica) provodi se nakon eliminacije uzoraka (odgovarajućih statističkih parametara koji se prate) koji su izvan kontrolnih granica.

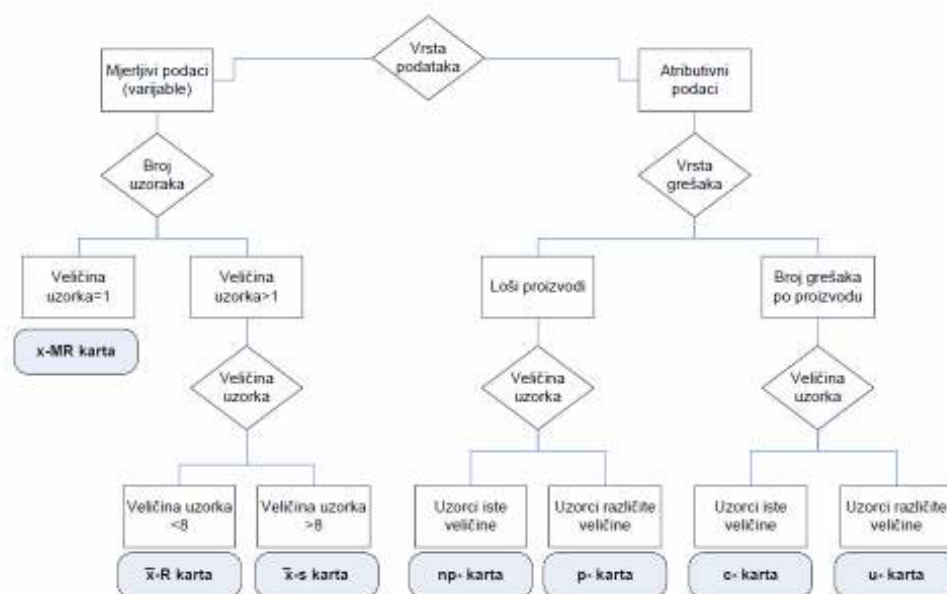
Za poznate procese (poznato rasipanje) kontrolne granice se postavljaju prije uzimanja uzoraka. To je i najprirodniji način korištenja kontrolnih karata jer se eventualna pojava značajnih odstupanja promptno može istražiti. Kontrolne karte treba odmaknuti od računala i približiti radnom mjestu (stroju).[2]

TRAJNO POBOLJŠAVANJE PROCESA

Niti jedno poboljšanje procesa ne odvija se preko noći. Poboljšanja se sastoje od sitnih koračića u dugom vremenskom razdoblju. Važno je znati kojim redom koračati (izbor prioriteta). Dinamiku korištenja kontrolnih karata treba prilagoditi učincima, mogućnostima poboljšavanja, preventivi i sl. Važno je znati što se hoće a ne samo stvarati lijepa kolor izvješća radi formalnog opravdanja svoje aktivnosti. S vremenom će i to sigurno prijeći u dosadu.[3]

3. VRSTE KONTROLNIH KARATA

Razlikujemo kontrolne karte za mjerljive karakteristike i kontrolne karte za atributivne karakteristike (promatraju se atributivni rezultati kontrole npr. dobro-loše i sl.).



Slika 2. Algoritam za izbor prikladne kontrolne karte[2]

3.1. Kontrolne karte za mjerljive karakteristike

3.1.1 \bar{x} -R karta

Njom se registriraju dva važna pokazatelja procesa:

- kretanje aritmetičkih sredina uzoraka
- kretanje raspona uzoraka R_i

Prvi podatak daje uvid u centriranost procesa, dok drugi R_i govori o njegovom rasipanju. Primjena joj dolazi kod izražaja kod serijske i velikoserijske komadne proizvodnje gdje se kontrola svodi na mjerenje malih uzoraka ($n = 2$ do 10 komada), te su troškovi kontrole znatno smanjeni. [2]

Kontrolne granice za \bar{x} -R kartu

Razlikujemo:

- a) Kontrolne granice za kretanje aritmetičkih sredina uzoraka

$$\frac{G}{D} KG_{\bar{x}} = \bar{\bar{x}} \pm 3\sigma_R; \quad \frac{G}{D} KG_{\bar{x}} = \bar{\bar{x}} \pm A_2 \bar{R}; \quad \bar{R} = \frac{\sum R_i}{k} \quad \text{gdje je } k \text{ broj obilazaka}$$


kontrolora, odnosno broj uzetih uzoraka.

Tablica 1. Koeficijenti kontrolnih granica za \bar{x} -R kartu[2]

n	A_2	D_3	D_4	d_2
2	1,880	0	3,267	1,128
3	1,023	0	2,575	1,693
4	0,729	0	2,282	2,059
5	0,577	0	2,115	2,326
6	0,483	0	2,004	2,534
7	0,419	0,076	1,924	2,704
8	0,373	0,136	1,864	2,847
9	0,337	0,184	1,816	2,970
10	0,308	0,223	1,777	3,078

b) Kontrolne granice za kretanje raspona uzoraka

$$\frac{G}{D} KG_R = \bar{R} \pm 3\sigma_R; \quad GKG_R = D_4 \bar{R}; \quad DKG_R = D_3 \bar{R}; \quad \hat{\sigma} = \frac{\bar{R}}{d_2}$$



Slika 3. \bar{x} -R karta [3]

3.1.2 \bar{x} -s karta

Karta prati dvije karakteristike procesa:

- njegovu centriranost preko kretanja aritmetičkih sredina uzoraka
- njegovo rasipanje preko kretanja standardnih odstupanja

Budući da se računaju standardna odstupanja uzoraka preporučuje se da veličina uzorka bude veća od 25.

Ove karte se primjenjuju u procesima koji su zaokruženog tipa i odvijaju se u zatvorenim ciklusima određene dužine trajanja kada se proces ne može pratiti dok je ciklus u toku. [2]

Kontrolne granice za \bar{x} -s kartu

Razlikujemo:

- a) kontrolne granice za kretanje aritmetičkih sredina uzoraka

$$\begin{matrix} G \\ D \end{matrix} KG_{\bar{x}} = \bar{\bar{x}} \pm 3\sigma_{\bar{x}}; \quad \begin{matrix} G \\ D \end{matrix} KG_{\bar{x}} = \bar{\bar{x}} \pm A_1 \bar{s}; \quad \bar{s} = \frac{\sum s_i}{k}$$

Gdje je k broj obilazaka kontrolora, odnosno broj uzetih uzoraka.

Standardno odstupanje:

$$s = \sqrt{\frac{\sum_{i=1}^n (x_i - \bar{x})^2}{n-1}}$$

- b) Kontrolne granice za kretanje standardnih odstupanja uzoraka

$$\begin{matrix} G \\ D \end{matrix} KG_R = \bar{s} \pm 3\sigma_{\sigma}; \quad GKG_s = B_4 \bar{s}; \quad DKG_s = B_3 \bar{s}; \quad \hat{\sigma} = \frac{\bar{s}}{c_2}$$

Tablica 2. Koeficijenti kontrolnih granica za \bar{x} -s karta[2]

n	A_1	B_3	B_4	C_2
10	1,028	0,284	1,716	0,9227
15	0,816	0,428	1,572	0,9400
20	0,697	0,510	1,490	0,9619
25	0,619	0,565	1,435	0,9696
30	0,562	0,603	1,397	0,9748
35	0,518	0,633	1,367	0,9784
40	0,483	0,658	1,342	0,9811
45	0,455	0,678	1,322	0,9832
50	0,431	0,695	1,305	0,9849
60	0,392	0,723	1,277	0,9874
70	0,363	0,744	1,256	0,9892

3.1.3 \bar{x} - MR (moving range) karta

Upotrebljava se u situacijama kada se ne može omogućiti statistički uzorak, odnosno kada je veličina uzorka jednaka jedinici ($n = 1$).[2]

Razlikujemo:

- a) Kontrolne granice za kretanje individualni vrijednosti mjerenja

$$\frac{G}{D} KG_x = \bar{x} \pm 2,66 \overline{MR} ; \text{ pri čemu je } MR_I = |x_2 - x_1| \dots \bar{x} = \frac{\sum_{i=1}^k x_i}{k} ; \overline{MR} = \frac{\sum_{i=1}^k MR}{k-1}$$

- b) Kontrolne granice za kretanje MR vrijednosti

$$GKG_{MR} = 3,27 \overline{MR} ; DKG_{MR} = 0$$

$$\hat{\sigma} = \frac{\overline{MR}}{d_2} = \frac{\overline{MR}}{1,128}$$

3.2. Kontrolne karte za atributivne karakteristike

3.2.1 p-karta

Prikazuje grafičko kretanje proporcije loših komada u uzorcima. Veličine uzoraka pri tome mogu biti različite. Matematička osnova je binomna razdioba. Radi

osjetljivosti karta vrlo dobro odgovara tek ako je broj loših komada u uzorku barem 4 ($n \cdot p \geq 4$).[2]

Srednja vrijednost omjera loših komada \bar{p} :

Ukupan broj loših komada u svim uzorcima se djeli s ukupnim brojem komada u svim uzorcima.

$$\bar{p} = \frac{n_1 \cdot p_1 + n_2 \cdot p_2 + \dots + n_k \cdot p_k}{n_1 + n_2 + \dots + n_k} = \frac{\sum_{i=1}^k n_i \cdot p_i}{\sum_{i=1}^k n_i}; \text{ pri čemu je } k \text{ broj uzoraka.}$$

Kontrolne granice iznose:

$$\frac{G}{D} KG = \bar{p} \pm 3 \sqrt{\frac{\bar{p}(1-\bar{p})}{n}}; \quad \sigma_p = \sqrt{\frac{\bar{p}(1-\bar{p})}{n}} \text{ pri čemu ukoliko je } \bar{p} < 0,1 \text{ vrijedi:}$$

$$\frac{G}{D} KG = \bar{p} \pm 3 \sqrt{\frac{\bar{p}}{n}}$$

3.2.2 np- karta

Neposredno prikazuje broj pronađenih škart jedinica u uzorku. Ova je karta primjenjiva kada je veličina uzoraka konstantna.

Prosječan broj loših komada po uzorku $n\bar{p}$ dobije se dijeljenjem ukupnog broja loših komada u svim uzorcima s brojem uzimanih uzoraka.[2]

$$\bar{p} = \frac{n_1 \cdot p_1 + n_2 \cdot p_2 + \dots + n_k \cdot p_k}{k} = \frac{\sum_{i=1}^k n_i \cdot p_i}{k}; \text{ pri čemu je } k \text{ broj uzoraka.}$$

Kontrolne granice se računaju:

$$\frac{G}{D} KG = n\bar{p} \pm 3 \sqrt{n\bar{p}(1-\bar{p})}; \quad \sigma_{np} = \sqrt{n\bar{p}(1-\bar{p})}; \text{ pri čemu ukoliko je } \bar{p} < 0,1 \text{ vrijedi:}$$

$$\frac{G}{D} KG = n\bar{p} \pm 3 \sqrt{n\bar{p}}$$

3.2.3 u-karta

Prikazuje prosječan broj grešaka iskazan na jedinicu proizvoda pronađenih u isporuci (uzorku). Veličine uzoraka pri tome mogu biti različite. Prosječan broj grešaka na jedinicu proizvoda \bar{u} dobije se dijeljenjem ukupnog broja grešaka na svim komadima s ukupnim brojem komada u svim uzorcima.[2]

$$\bar{u} = \frac{n_1 \cdot u_1 + n_2 \cdot u_2 + \dots + n_k \cdot u_k}{n_1 + n_2 + \dots + n_k} = \frac{\sum_{i=1}^k n_i \cdot u_i}{\sum_{i=1}^k n_i}$$

Kontrolne granice iznose:

$$\begin{matrix} G \\ D \end{matrix} KG = \bar{u} \pm 3\sqrt{\frac{\bar{u}}{n}}; \quad \sigma_u = \sqrt{\frac{\bar{u}}{n}}$$

3.2.4 c-karta

Prati broj grešaka na jednom proizvodu ili uzorku. Uzorci moraju biti iste veličine. Prosječan broj grešaka po uzorku \bar{c} računa se dijeljenjem ukupnog broja grešaka u svim uzorcima s brojem uzimanih uzoraka[2]:

$$\bar{c} = \frac{c_1 + c_2 + \dots + c_k}{k} = \frac{\sum_{i=1}^k c_i}{k}$$

Kontrolne granice se računaju:

$$\begin{matrix} G \\ D \end{matrix} KG = \bar{c} \pm 3\sqrt{\bar{c}}; \quad \sigma_c = \sqrt{\bar{c}}$$

4. PROCJENJIVANJE SPOSOBNOSTI PROCESA

Sposoban proces je onaj proces koji može proizvoditi jedinice (dijelove) unutar zahtijevanih granica (granica specifikacije). Sposobnost procesa se procjenjuje računanjem tzv. indeksa sposobnosti procesa.[3]

4.1. *Procjena sposobnosti procesa s podacima koji se rasipaju po normalnoj razdiobi*

Računanje i pravilna interpretacija indeksa sposobnosti procesa temelji se na slijedećim pretpostavkama:

- raspodjela podataka se može aproksimirati normalnom raspodjelom
- proces koji se razmatra je stabilan i bez značajnih uzroka varijacija (proces je pod kontrolom)
- pouzdana procjena sposobnosti procesa može se donijeti samo temeljem praćenja procesa primjenom odgovarajuće kontrolne karte i nakon dovođenja procesa u stanje statističke kontrole (stanje pod kontrolom)

Ukoliko proces nije pod kontrolom računanje indeksa sposobnosti je puka formalnost i zavaravanje! Otklanjanjem značajnih uzroka varijacija u procesu i dovođenjem sredine procesa u okoliš ciljane vrijednosti ima smisla procjenjivati njegovu sposobnost.[3]

TEMELJNI UVJET SPOSOBNOSTI PROCESA

Proces je sposoban ako je raspon zahtjeva veći ili jednak od raspona procesa. Raspon zahtjeva (tolerancijsko područje) T je područje između gornje (USL) i donje granice zahtjeva (LSL), odnosno $T = USL - LSL$.

Raspon procesa podrazumijeva područje unutar ± 3 standardna odstupanja (6σ) u odnosu na sredinu procesa (99,73 % površine ispod krivulje normalne raspodjele kojom se aproksimira proces).[3]

Temeljni uvjet sposobnosti procesa je: $T \geq 6\sigma$

4.2. Procjena sposobnosti procesa s podacima koji se ne rasipaju po normalnoj razdiobi

Izraz ne-normalne razdiobe podataka koristi se kada skup podataka statistički značajno odstupa od normalne, Gauss-ove, razdiobe. Provjera da li je skup podataka normalno distribuiran provodi se na način da se usporede veličine koje čine dobivenu razdiobu s veličinama koje bi bile u skladu s normalnom razdiobom ili usporedbom odabranih površina normalne razdiobe i stvarno dobivene razdiobe.[4]

Prije provođenja analize podataka koji se temelje na normalnoj razdiobi, potrebno je provjeriti da li se podaci koji se analiziraju rasipaju po normalnoj razdiobi. Ako analizirano ne-normalne podatke kao da su normalno distribuirani, rezultati analize nas mogu dovesti do pogrešnih zaključaka. Danas su dostupni mnogi softverski paketi koji omogućuju provođenje statističke analize podataka. Jedan od takvih paketa je Minitab koji će biti korišten tijekom izrade ovog rada. Minitab nudi opcije testiranja normalnosti podataka pomoću tri osnovna testa normalnosti [4]:

- Anderson-Darling
- Ryan-Joyner
- Kolmogorov-Smirnov

Za provjeru koja distribucija najbolje opisuje podatke, u programu Minitab se koristi opcija *Individual distribution identification*. [5]

Gore navedeni testovi normalnosti podataka temelje se na testiranju hipoteza. Nulta hipoteza pretpostavlja da podaci slijede normalnu razdiobu, a alternativna hipoteza pretpostavlja da podaci ne slijede normalnu razdiobu.[5]

4.2.1 Analiza sposobnosti procesa sa ne-normalnom razdiobom podataka

U svijetu koji nas okružuje postoje brojni primjeri procesa čiji se podaci ne ponašaju po normalnoj distribuciji. Ukoliko prirodno postoji donja ili gornja granica zahtjeva, kao što je nula donja granica zahtjeva za vremena trajanja ciklusa, tada će proces imati mnogo vrijednosti koje se priklanjaju nuli i distribucija će biti ukošena u lijevu stranu. Primjer prirodne donje granice zahtjeva je kada restoran obećava da će izvršiti dostavu najkasnije pola sata nakon dogovorenog vremena dostave, tada je nula prirodna donja granica zahtjeva.

Uzroci nepodvrgavanja podataka normalnoj razdiobi [4]:

1. Ekstremne vrijednosti – ukoliko u razdiobi postoji više ekstremnih vrijednosti.
2. Preklapanje dva ili više procesa – ukoliko podaci dolaze iz više procesa, operatera, smjena ili iz procesa koji se konstantno mijenja.
3. Diskriminacija zbog neodgovarajućih podataka – konstantno ponavljanje pogrešaka pri mjerenju ili mjerni uređaji sa slabom rezolucijom mogu kontinuirane i normalno raspodijeljene podatke prikazati kao diskretne i nenormalne.
4. Sortiranje podataka - ova je situacija moguća ako se podaci prikupljaju i analiziraju nakon sortiranja ili ako se određeni broj podataka, koji ne ulaze u tolerancijsko polje, eliminiraju iz daljnjih analiza.
5. Vrijednosti blizu nule ili prirodne granice – kod procesa gdje se mnogo vrijednosti priklanjaju nuli ili nekoj drugoj prirodnoj granici cijela će distribucija biti ukošena u lijevu ili desnu stranu.
6. Podaci slijede neku drugu poznatu distribuciju.

Budući da se podaci ne moraju nužno ponašati po normalnoj razdiobi postoji nekoliko načina postupanja s takvim podacima [4]:

- Ako su podaci u podskupovima normalno distribuirani, sposobnost cjelokupnog procesa može se procijeniti iz sposobnosti podskupova.
- Ako se podaci ne pokoravaju normalnoj razdiobi, a može se izvršiti njihova normalizacija, potrebno je obaviti taj postupak prije analize.
- Upotreba drugih distribucija (Weibull-ova, log-normalna).

Ako analizirani podaci odstupaju od normalne distribucije, a alati koje se rabe za analizu zahtijevaju da se ti isti podaci pokoravaju normalnoj distribuciji, potrebno ih je normalizirati. U tom slučaju provodi se transformacija podataka korištenjem Box-Cox ili Johnson transformacije da bi se dobili podaci koji se rasipaju po normalnoj razdiobi.[5]

5. INDEKSI SPOSOBNOSTI PROCESA

U literaturi se mogu naći različita tumačenja tzv. indeksa sposobnosti procesa. Ta su tumačenja često kontradiktorna i mogu unijeti zbrku u primjeni. Zbrka je uglavnom povezana s načinom procjenjivanja raspona procesa (standardnog odstupanja) i s tim u svezi primijenjene terminologije. [2]

Pregled indeksa sposobnosti procesa koji je naveden u nastavku sukladan je tumačenju tvrtke FORD.

Uvažavajući vrijeme odvijanja procesa procjenjivanje sposobnosti (pripadajući indeksi) može pripadati jednoj od slijedeće tri kategorije:

1. Sposobnost procesa u dužem vremenskom razdoblju (Long-Term Process Capability)
2. Preliminarna sposobnost procesa (Preliminary Process Capability)
3. Sposobnost u kratkom vremenskom razdoblju (Short-Term Capability)

Indeksi sposobnosti procesa računaju se nakon odvijanja procesa tijekom razložno dugog vremenskog razdoblja u kojem su se mogli pojaviti svi mogući utjecaji varijacija procesa. Preporuka je 20 proizvodnih dana. Indeksi su slijedeći:

5.1. *Potencijalna sposobnost C_p (Potential Capability)*

Dobiva se iz temeljnog uvjeta sposobnosti, odnosno: $C_p = \frac{T}{6\sigma}$


Standardno odstupanje se procjenjuje analizom odgovarajuće kontrolne karte, odnosno iz izraza:

$$\hat{\sigma} = \frac{\bar{R}}{d_2} \quad (\text{u slučaju primjene } \bar{x} - R \text{ kontrolne karte) ili}$$
$$\hat{\sigma} = \frac{\bar{s}}{c_2} \quad (\text{u slučaju primjene } \bar{x} - s \text{ kontrolne karte}).$$

Ovako procijenjeno standardno odstupanje naziva se standardno odstupanje iz uzoraka ili unutrašnje standardno odstupanje (within subgroups or internal standard deviation).

Iznos indeksa C_p neposredno pokazuje je li proces može biti sposoban. Što je iznos indeksa veći to je rasipanje procesa manje.

U razvijenim zemljama danas se zahtjeva da najmanja vrijednost indeksa C_p iznosi 1,33. Taj zahtjev neke kompanije podižu na 1,67, odnosno na $C_p \geq 2$, slika 4.[2]



Slika 4. Prikaz razdiobe za različite potencijalne sposobnosti procesa[2]

5.2. Omjer sposobnosti C_r (Capability Ratio)

Iznos ovog indeksa je recipročna vrijednost indeksa C_p , odnosno: $C_r = 1 / C_p$. Ako se iznos ovog indeksa prikaže u postocima ($C_r \cdot 100$, %) dobiva se postotak tolerancijskog područja koji je iskorišten rasponom procesa. Za sposoban proces iznos indeksa C_r treba biti manji od 1.

5.3. Donja i gornja potencijalna sposobnost C_{pL} i C_{pU} (Lower and Upper potential capability)

Iznosi indeksa C_{pL} i C_{pU} računaju se korištenjem slijedećih izraza:

$$C_{pL} = (\text{sredina procesa} - L) / 3 \cdot \hat{\sigma}$$


$$C_{pU} = (U - \text{sredina procesa}) / 3 \cdot \hat{\sigma}$$

Sredina procesa je središnja linija primijenjene kontrolne karte. U slučaju računanja statističkih parametara iz svih podataka sredina procesa odgovara aritmetičkoj sredini tih podataka.

Indeksi C_p i C_r ne pokazuju kako je smješten proces u odnosu na granice specifikacija. To se može utvrditi usporedbom iznosa indeksa C_{pL} i C_{pU} :

- identični iznosi ukazuju na potpunu centriranost procesa (iznosi indeksa jednaki su iznosu indeksa C_p);
- iznos manji od 1 ukazuje na pojavu nesukladnosti;
- proces je pomaknut prema granici specifikacije manjeg iznosa indeksa.

Ovi indeksi se računaju u slučaju procjenjivanja sposobnosti procesa kada je dan jednostrani zahtjev na proces (samo jedna granica specifikacije), slika 5.[2]



Slika 5. Razdioba s jednom granicom specifikacije[2]

5.4. Faktor korekcije necentriranosti k (Non-centering correction)

Iznos indeksa C_p može se korigirati zbog necentriranosti računanjem faktora korekcije necentriranosti k [3]:

$$k = \text{abs}(D - \text{sredina procesa}) / (1/2 * (USL - LSL))$$

gdje je D ciljana vrijednost procesa, odnosno:

$$D = (USL + LSL)/2$$


5.5. Demonstrirana izvrsnost C_{pk} (Demonstrated excellence)

Korigirana vrijednost indeksa C_p zbog necentriranosti iznosi:

$$C_{pk} = (1 - k) C_p$$

Ako je proces idealno centriran tada je k jednak nuli i $C_{pk} = C_p$.

Pomicanjem procesa od ciljane vrijednosti (sredine područja tolerancija) k se povećava a C_{pk} postaje manji od C_p [3].



Slika 6. Razdioba pomaknutog procesa[2]

5.6. Stvarna sposobnost procesa P_p (Performance Process)


Ako se u postupku procjene standardnog odstupanja koriste svi podaci iz uzoraka kontrolne karte dobiva se tzv. „ukupno standardno odstupanje“ (engl. overall standard deviation) temeljem kojeg se računa indeks stvarne sposobnosti procesa (engl. Performance Process):

$$P_p = \frac{T}{6\hat{\sigma}} \quad \hat{\sigma} = \sqrt{\frac{\sum (x_i - \bar{x})^2}{n-1}}$$


Ovaj indeks se može računati i bez primjene kontrolne karte. Nužno je koristiti barem 300 podataka.

Iznos indeksa P_p varira u funkciji pomaka procesa u promatranom vremenskom razdoblju. Ako su u procesu prisutne samo slučajne varijacije tada su vrijednosti indeksa P_p i C_p jednake. U općem slučaju iznos indeksa P_p je uvijek manji od iznosa indeksa C_p osim ako nije analiziran dovoljno velik broj podataka, slika 8, 9., 10. i 11.


Ako su vrijednosti indeksa C_p i P_p vrlo bliske to znači da nije moguće poboljšati kvalitetu procesa ako se ne izvrši određena promjena u proizvodnim resursima [2].




Slika 7. Kontrolna karta proizvodnog procesa koji je pod kontrolom [2]



Slika 8. Kontrolna karta proizvodnog procesa koji nije pod kontrolom [2]



Slika 9. Procjena sposobnosti procesa za proizvodni proces koji je pod kontrolom [2]



Slika 10. Procjena sposobnosti procesa za proizvodni proces koji nije pod kontrolom [2]

5.7. Preliminarna sposobnost procesa (Preliminary Process Capability)

Preliminarno procjenjivanje sposobnosti procesa provodi se na početku odvijanja procesa ili nakon relativno kratkog vremena praćenja procesa. Preporuka je da se razmatra uzorak od najmanje 100 jedinica ili kontrolna karta s najmanje 20 uzoraka. U nazivlju indeksa se umjesto termina sposobnost (Capability) koristi termin značajka (Performance). U tom smislu se indeksi označavaju kao P_p , P_{pL} , P_{pU} , P_{pk} , a računaju se na isti način kao C_p , C_{pL} , C_{pU} , C_{pk} .

Zahtjevi na najmanje iznose indeksa P_p i P_{pk} su stroži nego za iznose indeksa C_p i C_{pk} (npr. ako je zahtjev za $C_p \geq 1,33$ tada je ekvivalentni zahtjev za $P_p \geq 1,67$). U SPC softverima za računanje ovih indeksa koristi se ukupno standardno odstupanje. Ukupno standardno odstupanje računa se iz izraza:

$$s = \sqrt{\frac{\sum_{i=1}^n (x_i - \bar{x})^2}{n-1}}$$

5.8. Sposobnost u kratkom vremenskom razdoblju (Short-Term Capability)

Za analizu sposobnosti procesa u kratkom vremenskom razdoblju često se koristi termin analiza sposobnosti stroja (Machine Capability Analysis). Primjenjuje se, u pravilu, prilikom pred-preuzimanja ili preuzimanja stroja. Preporučuje se provođenje analize na uzorku od najmanje 50 jedinica. Temeljni interes je informacija o rasipanju podataka oko ciljane vrijednosti D .

5.9. Potencijalna sposobnost stroja C_{pm} (Potential Machine Capability)

C_{pm} se računa korištenjem alternativne procjene standardnog odstupanja koja sadrži efekt slučajne necentriranosti (rasipanja oko ciljane vrijednosti), odnosno:

$$\hat{\sigma} = \{\sum (x_i - D)^2 / (n-1)\}^{1/2}$$

$$C_{pm} = (USL - LSL) / 6 \hat{\sigma}$$

6. EKSPERIMENTALAN DIO

6.1. O poduzeću



Slika 11. Logo tvrtke Štefan d.o.o.

Štefan d.o.o., slika 11, je manje poduzeće koja se bavi obradom metala i proizvodnjom gotovih proizvoda od metala. Poduzeće se nalazi u Kumrovcu i zapošljava 32 djelatnika i djelatnica, slika 14. U svojem proizvodnom programu imaju narezne prstenove različitih tipova i dimenzija, te dijelove za strojeve za velikoserijsko automatsko pakiranje. Svoje uspješne poslovne rezultate duguje orijentaciji prema vanjskom tržištu, točnije prema Njemačkoj, gdje već nekoliko godina uspješno surađuju s tvrtkama kao što su Volz GmbH (slika 12.), Conexa GmbH, Focke GmbH (slika 13), te Autex GmbH i dr.



Slika 12. Logo njemačke tvrtke Volz GmbH



Slika 13. Logo njemačke tvrtke Focke GmbH



Slika 14. Poslovni objekt i proizvodni pogon tvrtke Štefan d.o.o.

6.2. Predmet mjerenja


6.2.1 Ukratko o narezanim prstenovima

Narezni prsten je dio sklopa za povezivanje metričkih cijevi koji se sastoji od tijela, nareznog prstena i matice, slika 15. Sklop nareznog prstena stvara nepropustan i čvrst spoj otporan na visok i nizak tlak između cijevi i komponenti hidrauličkih sustava. Osnovna funkcija nareznog prstena je da kontrolirano reže u vanjsku površinu cijevi zbog svoje jedinstvene unutarnje geometrije [6].

Zatezanjem matice u tijelo, prednji i sekundarni rezni rub nareznog prstena zarežu cijev na zadanu dubinu, daljnje napredovanje u dubinu je onemogućeno zaustavnim rubom, slika 16 [6].



Slika 15. Rastavljeni sklop nareznog prstena za spajanje cijevi - po redu od lijevo nalazi se tijelo, narezni prsten i matica [6]



Slika 16. Detaljni prikaz sklopa nareznog prstena [6]


Najčešći materijal od kojeg se proizvode narezni prstenovi je nehrđajući čelik X6CrNiMoTi 17122 (materijal broj 1.4571). Narezni prsten nakon strojne obrade ide na toplinsku obradu kako bi se povećala tvrdoća, čvrstoća i žilavost [6].

6.2.2 Narezni prsten pdr12LS

Predmet mjerenja ovog rada je narezni prsten oznake pdr12LS, slika 17. i 18., unutarnjeg promjera od 12 mm koji proizvodi tvrtka Štefan d.o.o za jednog njemačkog naručitelja, čije ime se ne smije navesti zbog povjerljivosti podataka.



Slika 17. Predmet mjerenja – narezni prsten pdr12LS



Slika 18. CAD model predmeta mjerenja

Navedeni prsten se proizvodi u serijama od 15 000 komada, pri čemu se proizvodi u tri ili dvije smjene ovisno o hitnosti (prioritetu) narudžbe. U jednoj smjeni se proizvede otprilike 500 komada. S obzirom na te podatke odlučeno je da će se


uzimati po dva uzorka za mjerenje u svakoj smjeni, nakon tri sata i nakon šest sati. Veličina uzorka je $n = 3$ komada, što znači da je mjereno ukupno 18 komada dnevno. Mjerenja su trajala dok se nije dostigao broj mjerenja od 250 komada, što iznosi ukupno 1,67% izmjerenih komada od ukupnog broja serije, što je dovoljno da se donesu zaključci vezani uz \bar{x} - R kontrolnu kartu i procjenu sposobnosti procesa.

Tijekom mjerenja praćeno je 8 veličina, odnosno svaka dimenzija kotirana u nacrtu nareznog prstena koja sadrži vrijednosti s tolerancijama mjera, tablica 3 i slika 19. Svakoj veličini je dan naziv koji se kolokvijalno koristi u proizvodnom pogonu, slika 20, zbog jednostavnosti i preglednosti tablice mjerenja u koju su upisivani rezultati mjerenja za svaku pojedinu veličinu.


Tablica 3. Tablica mjerenih veličina i vrijednosti kota s donjim i gornjim granicama dimenzija

	<i>Iznos kotirane vrijednosti</i>	<i>Donja granica tolerancijskog polja</i>	<i>Gornja granica tolerancijskog polja</i>
Odrez	$45^\circ \pm 0,25^\circ$	$44,75^\circ$	$45,25^\circ$
Vanjski kut	$10^\circ \pm 0,5^\circ$	$9,5^\circ$	$10,5^\circ$
Unutarnji kut	$8_{0^{\circ}}^{+1^{\circ}}$	8°	9°
Vanjski radijus	$R0,2_{0}^{+0,2}$ mm	0,2 mm	0,4 mm
Unutarnji radijus	$R0,2_{-0,05}^{+0,1}$ mm	0,195 mm	0,3 mm
Vanjska dužina	$5_{0}^{+0,1}$ mm	5 mm	5,1 mm
Srednja dužina	$3,2_{0}^{+0,1}$ mm	3,2 mm	3,3 mm
Unutarnja dužina	$2_{-0,1}^{0}$ mm	2 mm	1,9 mm

Dobivena geometrija nareznog prstena rezultat je strojne obrade tri rezna alata na tokarskom obradnom centru. Obrada nožem za odrez, unutarnjom pločicom za finu obradu za unutarnji kut, unutarnji radijus i unutarnju dužinu, dok se obradom vanjskom pločicom za finu obradu obrađuje vanjski kut, vanjski radijus, unutarnji radijus, vanjsku i srednju dužinu.



Slika 19. Nacrt s mjerenim veličinama koje sadrže tolerancije mjera




Slika 20. Nacrt s nazivima mjerenih veličina

6.3. Sredstvo mjerenja

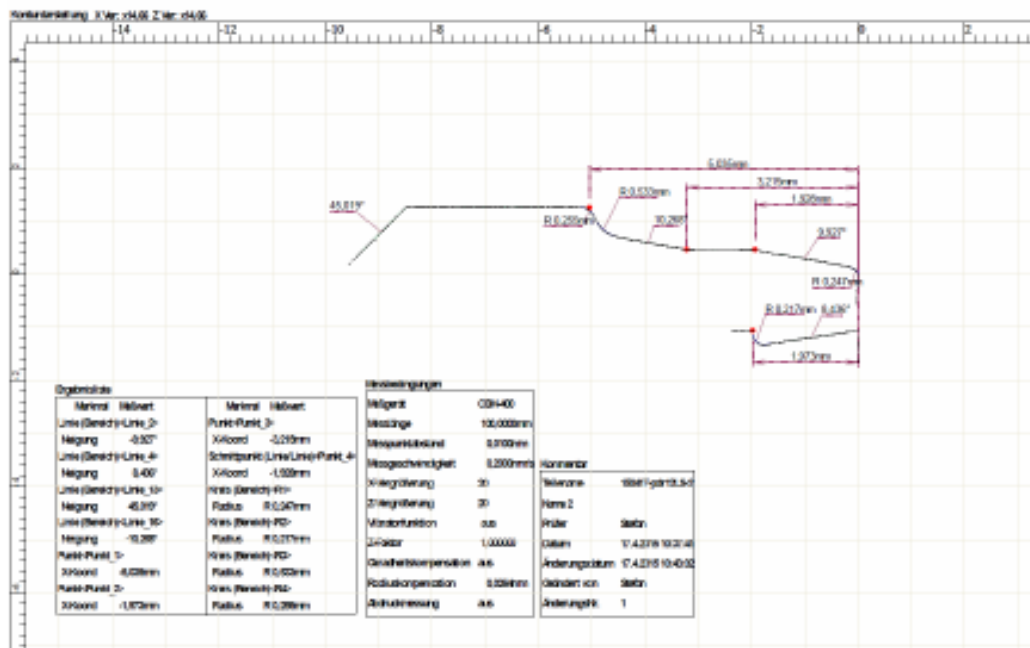
Mjerenja su obavljena pomoću uređaja za mjerenje konture Mitutoyo Contracer CBH-400 kojim raspolaže tvrtka Štefan d.o.o., slika 21. Mjerni uređaj je povezan s računalom koje nakon obavljenog mjerenja signale dobivene od mjernog uređaja obrađuje pomoću softverskog paketa Formpak, slika 22., i prikazuje ih na ekranu, koji se potom kotira kako bi se dobio nacrt predmeta mjerenja, slika 23.



Slika 21. Mjerno sredstvo Mitutoyo Contracer CBH-400 i računalno.



Slika 22. Formpak-programski paket za obradu podataka
mjerenja dobivenih mjernim sredstvom



Slika 23. Obradjeni i kotirani nacrt predmeta mjerenja

Karakteristike mjernog sredstva su sljedeće [7]:

- Raspon mjerenja - X os - 100 mm
- Z os - 50 mm
- Rezolucija izlaznih podataka - X os - 0,1 μm
- Z os - 0,2 μm - 4 μm (ovisno o povećanju)
- Mjerna točnost -X os - $\pm(2+L/100)$ μm
-Z os - $\pm 0,25\%$ cijele dužine raspona mjerenja
-pravocrtnost 1 $\mu\text{m}/100$ mm
- Kut mjerenja – mogućnost mjerenja kuta uspona od 77° i padajućeg kuta od 87° ovisno o konturi koja se mjeri
- Brzina mjerenja – 0,02-1 mm/s
- Sila mjerenja – 0,03 N

Mjerenja su obavljena u mjernom području od $\pm 6,25$ mm s brzinom mjerenja od 0,02 mm/s. Iako postoji mogućnost mnogo preciznijeg mjerenja na ovom mjernom uređaju, odabrana je manja preciznost i veća brzina mjerenja, jer za zadane tolerancije mjera koje zahtjeva kupac nije potrebna veća preciznost. Smanjenje mjernog područja i brzine mjerenja drastično povećava vrijeme mjerenja.

7. REZULTATI


Ukupno je izmjereno 252 komada tijekom 17 dana. 11 dana su uzimani uzorci u 3 smjene, nakon čega se proizvodnja zbog kvara tokarskog obradnog centra ostalih 6 dana nastavlja u dvije smjene. Podaci su upisivani u tablicu gdje se za svaku veličinu pratio broj smjene, datum mjerenja i broj dana mjerenja, tablica 4. Analiza je provedena primjenom probne verzije statističkog paketa Minitab 17 u kojem su se rezultati primijenili za izradu \bar{x} -R kontrolnih karata i procjenu sposobnosti proizvodnog procesa za svaku veličinu.

Tablica 4. Dio tablice s mjerenjima

redni broj	Odrez [°]	vanjski kut [°]	unutarnji kut [°]	vanjski radius [mm]	unutarnji radius [mm]	vanjska dužina [mm]	srednja dužina [mm]	unutarnja dužina [mm]	Smjena [mm]	dan	broj dana
49	44,838	10,082	8,423	0,296	0,225	5,059	3,266	1,95	3	16.4.	4
50	44,866	10,095	8,544	0,293	0,208	5,047	3,241	1,971	3	16.4.	4
51	44,988	10,126	8,681	0,276	0,213	5,061	3,245	1,968	3	16.4.	4
52	44,884	9,963	8,542	0,274	0,204	5,037	3,273	1,977	3	16.4.	4
53	44,864	10,096	8,496	0,252	0,202	5,061	3,279	1,97	3	16.4.	4
54	44,929	9,981	8,482	0,227	0,213	5,047	3,249	1,958	3	16.4.	4
55	45,019	10,104	8,685	0,242	0,221	5,055	3,234	1,961	1	16.4.	4
56	44,975	10,135	8,496	0,242	0,24	5,079	3,265	1,959	1	16.4.	4
57	45,132	9,966	8,424	0,271	0,208	5,075	3,24	1,973	1	16.4.	4
58	45,038	10,189	8,396	0,225	0,203	5,048	3,231	1,97	1	16.4.	4
59	45,092	9,93	8,426	0,219	0,228	5,045	3,227	1,963	1	16.4.	4
60	44,921	9,834	8,407	0,22	0,224	5,037	3,236	1,946	1	16.4.	4
61	44,857	10,055	8,459	0,23	0,231	5,042	3,223	1,949	2	16.4.	4
62	44,984	10,035	8,308	0,226	0,234	5,026	3,274	1,949	2	16.4.	4
63	45,012	10,017	8,245	0,21	0,205	5,025	3,224	1,941	2	16.4.	4
64	45,08	9,923	8,466	0,217	0,268	5,059	3,223	1,933	2	16.4.	4
65	44,932	9,778	8,483	0,226	0,264	5,036	3,252	1,987	2	16.4.	4
66	44,954	9,984	8,571	0,216	0,22	5,021	3,221	1,949	2	16.4.	4
67	45,016	9,945	8,414	0,238	0,221	5,065	3,248	1,951	3	17.4.	5
68	45,142	10,038	8,154	0,243	0,222	5,057	3,265	1,95	3	17.4.	5
69	45,079	10,055	8,457	0,247	0,218	5,058	3,246	1,963	3	17.4.	5
70	44,952	9,971	8,431	0,246	0,242	5,069	3,247	1,958	3	17.4.	5
71	45,029	9,94	8,438	0,259	0,216	5,053	3,223	1,957	3	17.4.	5
72	44,932	9,973	8,089	0,233	0,241	5,059	3,241	1,953	3	17.4.	5
73	44,926	9,907	8,559	0,227	0,211	5,045	3,251	1,959	1	17.4.	5
74	45,077	9,853	8,333	0,209	0,235	5,061	3,239	1,951	1	17.4.	5
75	44,972	9,924	8,339	0,219	0,254	5,056	3,211	1,962	1	17.4.	5
76	44,828	9,848	8,594	0,273	0,199	5,046	3,233	1,955	1	17.4.	5
77	45,025	9,961	8,484	0,232	0,209	5,037	3,235	1,957	1	17.4.	5
78	45,096	9,936	8,376	0,218	0,2	5,034	3,223	1,956	1	17.4.	5


7.1. \bar{x} -R kontrolne karte

Zbog nejednolikih veličina uzoraka koji su uzimani po danima zbog promjene broja smjena tijekom kojih se proizvodio predmet mjerenja, u postavkama Minitab-a za veličinu uzoraka bilo je potrebno postaviti pretpostavljenu veličinu uzoraka $n = 6$ kako bi se rezultati mogli prikazati po danima.




Slika 24. \bar{x} -R kontrolna karta za odrez

Prvim dobivenim rezultatima za odrez, slika 24., uočeno je da proizvodni proces nije pod kontrolom zbog uzorka osmog dana koji izlaze izvan granica kontrolne granice za raspon. Detaljnijim pregledom tablice s podacima uočeno je da je do greške došlo u trećoj smjeni osmog dana mjerenja, te je utvrđeno da su rezultati drugačiji od ostalih dana zbog prekasne promjene alata. S obzirom da su rezultati mjerenja ostalih uzoraka u granicama kontrolne karte ukoliko operater pripazi na pravovremenu izmjenu alata, podaci iz treće smjene, osmog dana mogu se izostaviti.




Slika 25. \bar{X} -R kontrolna karta za odrez nakon korigiranih podataka

Nakon izrade nove kontrolne karte s korigiranim ulaznim podacima, s obzirom da se svi uzorci nalaze unutar kontrolnih granica, slika 25., može se zaključiti da je proizvodni proces za odrez pod kontrolom. Može se uočiti da aritmetička sredina uzoraka ima rastući trend, na što se može djelovati vrlo jednostavno ranijom izmjenom alata.




Slika 26. \bar{X} -R kontrolna karta za vanjski kut

Prvim dobivenim rezultatima za vanjski kut, slika 26., uočeno je da proizvodni proces nije pod kontrolom zbog uzoraka koji su uzeti drugog i četvrtog dana koji izlaze izvan granica kontrolne granice za raspon. Pregledom tablice s podacima uočeno je da je na nekoliko komada koji su izmjereni, veličina vanjskog kuta ima drastično veći kut, što je vrlo vjerojatno posljedica ne odstranjene odvojene čestice. Do tih anomalija dolazi zbog relativno lošeg polijevanja hladila (emulzije) po mjestu obrade, koje osim efekta hlađenja također i izbacuje odstranjenu česticu. S obzirom da je to neizbježna posljedica, ti podaci će biti izostavljeni.




Slika 27. \bar{x} -R kontrolna karta za vanjski kut nakon korigiranih podataka

Nakon izrade nove kontrolne karte s korigiranim ulaznim podacima, s obzirom da se svi uzorci nalaze unutar kontrolnih granica, slika 27., može se zaključiti da je proizvodni proces za vanjski kut pod kontrolom. Krivulja aritmetičke sredine nema ni padajući ni rastući trend, što znači da proizvodni proces za vanjski kut ne treba poboljšavati, te da se postojeći podaci mogu iskoristiti za računanje procjene sposobnosti proizvodnog procesa za vanjski kut.




Slika 28. \bar{x} -R kontrolna karta za unutarnji kut

Prvim dobivenim rezultatima za unutarnji kut, slika 28., uočeno je da proizvodni proces nije pod kontrolom tijekom prvih tjedan dana jer polovica uzoraka prelazi granice raspona, te aritmetička sredina uzoraka osmog dana mjerenja ima premali kut. Do nagle promjene i normalizacije podataka osmog dana je došlo zbog promjene vrste alata i smanjenja režima rada, naime Widia svrdlo je zamijenjeno HSS svrdlom, te je još smanjena posmična brzina. S obzirom da su veličine nakon promjene vrste alata bili u sredini tolerancijskog polja, svi podaci čije su vrijednosti manje od uobičajenih tijekom prvih tjedan dana mjerenja će biti zanemareni.




Slika 29. \bar{x} -R kontrolna karta za unutarnji kut nakon korigiranih podataka

Korigiranom kontrolnom kartom za unutarnji kut, slika 29., posebice ako gledamo centriranost i rasipanje procesa u drugoj polovici mjerenja, može se primijetiti da se centriranost i rasipanje procesa u cijelom radu nalaze unutar kontrolnih granica, te ukoliko se zanemari prvi dio mjerenja, nemaju ni rastući ni padajući trend, može se zaključiti da je proces pod kontrolom, te da se podaci mogu iskoristiti za procjenu sposobnosti proizvodnog procesa za unutarnji kut.




Slika 30. \bar{x} -R kontrolna karta za vanjski radijus

Prvim dobivenim rezultatima za vanjski radijus, slika 30., uočeno je da proizvodni proces nije pod kontrolom zbog uzorka šestog dana čija vrijednost prelazi gornju kontrolnu granicu za R kartu. Pregledom je utvrđeno da se povremeno vrijednost vanjskog radijusa drastično povećava. Treba također napomenuti da se vanjski radijus izrađuje istim alatom kojim se izrađuje i vanjski kut, tako da je povećanje vrlo vjerojatno posljedica neodstranjene čestice koja je zaostala nakon strojne obrade, kao i kod vanjskog kuta. S obzirom da do toga također ne dolazi prečesto i da je to neizbježna posljedica, ti podaci će biti izostavljeni.




Slika 31. \bar{x} -R kontrolna karta za vanjski radijus nakon korigiranih podataka

Nakon izrade nove kontrolne karte s korigiranim ulaznim podacima, s obzirom da se svi uzorci nalaze unutar kontrolnih granica, slika 31., može se zaključiti da je proizvodni proces za vanjski radijus pod kontrolom. S obzirom na poprilično stohastički izgled \bar{x} centriranosti i rasipanja procesa, ne može se zaključiti da li ima padajući ili rastući trend, zbog toga bi trebalo nastaviti s mjerenjima kako bi moglo uočiti gibanje centriranosti i rasipanja procesa, kako bi se moglo zaključiti potrebno li je mijenjati proizvodni proces.




Slika 32. \bar{x} -R kontrolna karta za unutarnji radijus

Prvim dobivenim rezultatima za unutarnji kut, slika 32., uočeno je da proizvodni proces nije pod kontrolom zbog uzoraka koji su uzeti drugog i četvrtog dan koji izlaze izvan granica kontrolne granice za raspon. Vrlo velika je vjerojatnost da je za takve izlazne podatke zaslužena također neodstranjena odvojena čestica u kombiniranom slučaju s prekasnom izmjenom alata. S obzirom da su mjerenja nakon trećeg dana unutar kontrolnih granica, sve vrijednosti veličina koje su izvan granica drugog i trećeg dana će se zanemariti.




Slika 33. \bar{x} -R kontrolna karta za unutarnji radijus nakon korigiranih podataka

Nakon izrade korigirane \bar{x} -R karte za unutarnji radijus centriranost i rasipanje procesa nalaze unutar kontrolnih granica, tako da se može zaključiti da je proces pod kontrolom. Stohastički izgled centriranosti i rasipanja procesa je posljedica problema odstranjivanja odvojene čestice iz provrta prstena, slika 33.




Slika 34. \bar{x} - R kontrolna karta za vanjsku dužinu

Prvim uvidom \bar{x} - R kontrolne karte može se primijetiti da centriranost i rasipanje procese prelazi kontrolne granice što znači da proces nije pod kontrolom, slika 34. Takav zaključak treba prihvatiti s oprezom, jer treba napomenuti da se kotiranje svih dužina odvija proizvoljno, jer je nemoguće naći točno sjecište bridova jer se na svakom od bridova nalazi zaobljenje R0,2-R0,8 mm. Upravo zato je izgled centriranosti i rasipanja procesa stohastičan, a i podaci koji značajno odstupaju od ostalih veličina mogu se zanemariti.




Slika 35. \bar{x} - R kontrolna karta za vanjsku dužinu nakon korigiranih podataka

Korekcijom podataka dobili smo centriranost i rasipanje procesa koje se nalazi unutar kontrolnih granica, slika 35., te se može donijeti zaključak da je proces pod kontrolom. Treba napomenuti da je vrijednost vanjske dužine direktno povezana s vrijednosti vanjskog kuta. Ukoliko je geometrija alata kojim se dobiva vanjski kut, dobra, tada je vrijednost vanjske dužine u granicama tolerancije.




Slika 36. \bar{x} -R kontrolna karta za srednju dužinu

Uvidom u \bar{x} -R kontrolnu kartu može se primijetiti da centriranost i rasipanje procesa prelazi kontrolne granice što znači da proces nije pod kontrolom, slika 36. Ovdje se javlja jednak slučaj kao i kod vanjske dužine, tako da svi podaci koji značajno odstupaju od ostalih veličina mogu se zanemariti.




Slika 37. \bar{x} -R kontrolna karta za srednju dužinu nakon korigiranih podataka

Korekcijom podataka dobili smo centriranost i rasipanje procesa koje se nalazi unutar kontrolnih granica, slika 37., te se može donijeti zaključak da je proces pod kontrolom. Treba napomenuti da je vrijednost srednje, kao i vanjske, dužine direktno povezana s vrijednosti vanjskog kuta. Ukoliko je geometrija alata kojim se dobiva vanjski kut, dobra, tada je vrijednost srednje dužine, kao i vanjske dužine, u granicama tolerancije.



Slika 38. \bar{x} -R kontrolna karta za unutarnju dužinu

Krivulja R karte prelazi gornju kontrolnu granicu, slika 38., tako da proces nije pod kontrolom, no međutim pregledom podatak je utvrđeno da je napravljena greška u prilikom podataka u tablicu mjerenja tijekom trećeg dana mjerenja, tako da je jedan uzorak izostavljen.



Slika 39. \bar{x} -R kontrolna karta za unutarnju dužinu nakon korigiranih podataka

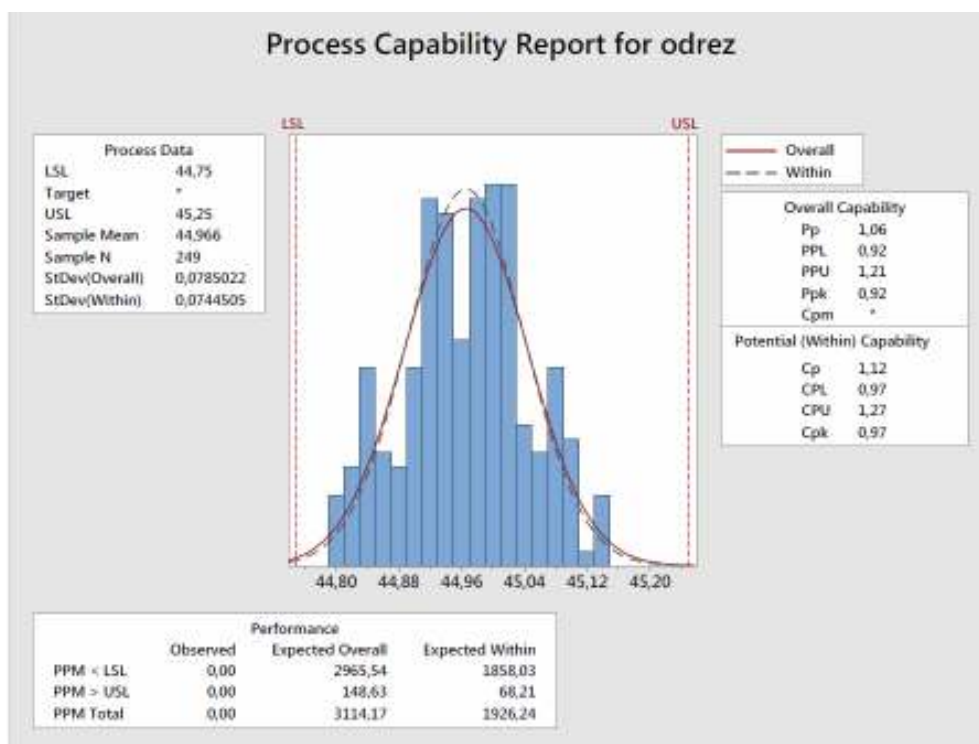
Korekcijom podataka dobili smo centriranosti i rasipanja procesa koje se nalazi unutar kontrolnih granica, slika 39., te se može donijeti zaključak da je proces pod kontrolom. Vrijednost unutarnje dužine direktno je povezana s vrijednosti unutarnjeg kuta. Ukoliko je geometrija alata kojim se dobiva unutarnji kut, dobra, tada je vrijednost unutarnje dužine u granicama tolerancije.

\bar{x} -R kontrolnim kartama smo utvrdili da je proizvodni proces za svaku veličinu pod kontrolom, tako da se može napraviti procjena sposobnosti proizvodnog procesa. Potrebno je istaknuti da se cjelokupan proizvodni proces mogao pratiti preko tri veličine, a to su odrez, vanjski i unutarnji kut. Ukoliko su te tri veličine pod kontrolom, tada će i ostale veličine također biti pod kontrolom. Do toga dolazi jer se geometrija alata za strojnu obradu može provjeriti provjerom vrijednosti veličina kutova, ukoliko su kutovi unutar kontrolnih granica, tada je geometrija alata još uvijek zadovoljavajuća za proizvodnju i nije potrebna njegova izmjena.

Prilikom mjerenja predmeta mjerenja dogodilo se nekoliko anomalija koje su drastično promijenile vrijednosti veličina i koje su se mogle uočiti i predvidjeti pregledom kontrolnih karata. Prva anomalija je posljedica da su operateri primijetili da će ih se češće kontrolirati te su zbog toga nešto češće mijenjali alat. Druga se može smatrati promjenom vrste svrdla kod unutarnjeg kuta. Te na kraju treća koja se dogodila zbog kvara stroja, što je imalo za posljedicu nastavak proizvodnje u dvije smjene.

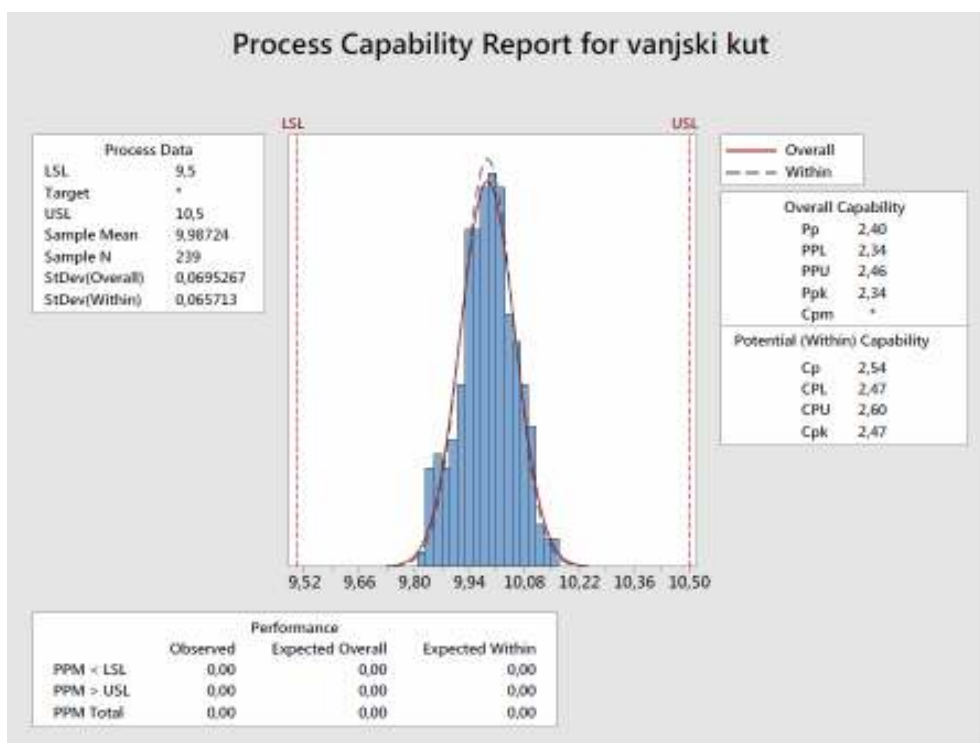
7.2. Sposobnost proizvodnog procesa

Za procjenu sposobnosti procesa je također korišten softverski paket Minitab. Prilikom izračuna za svaku je veličinu upisivana gornja i donja granica tolerancijskog polja, tablica 3.



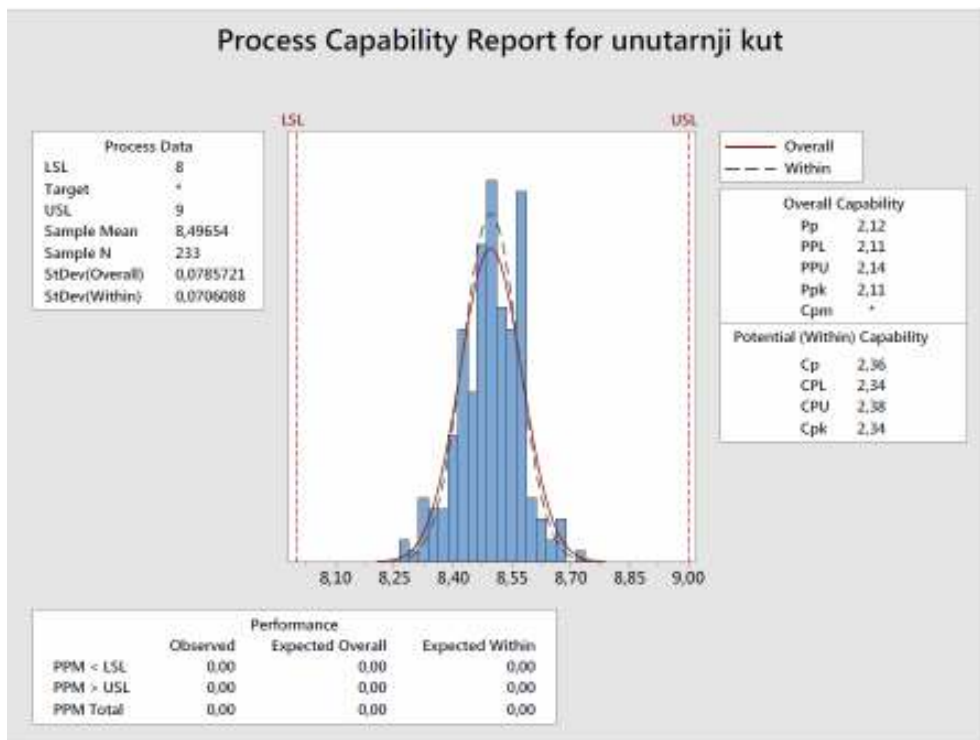
Slika 40. Procjena sposobnosti procesa za odrez

Grafički prikaz prikazuje da je proces pomaknut blago u lijevo, odnosno prema donjoj granici $LSL = 44,75$ mm. Stvarna sposobnost procesa $P_p = 1,06$ ($P_p > 1$), prema čemu se može zaključiti da je proces sposoban. Međutim potencijalna sposobnost iznosi $C_p = 1,12$, odnosno $P_p < C_p$ što znači da ima prostora za poboljšavanje sposobnosti procesa, slika 40.



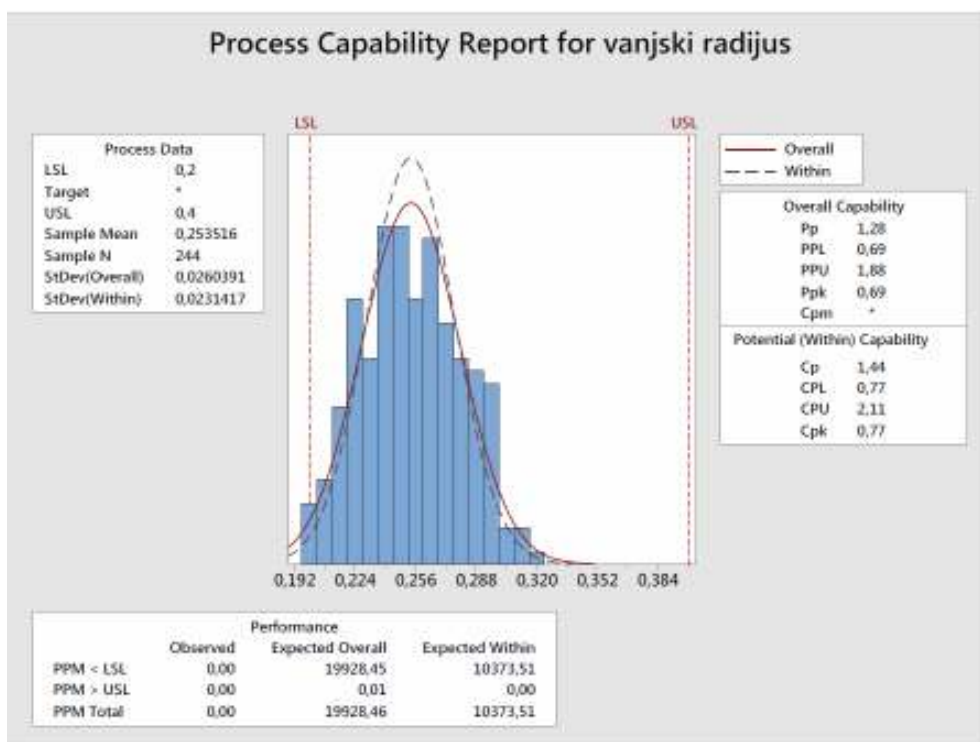
Slika 41. Procjena sposobnosti procesa za vanjski kut

Grafički prikaz procjene sposobnosti za vanjski kut prikazuje centriran proces, sa stvarnom sposobnosti procesa $P_p = 2,40$, što zadovoljava sve suvremene standarde ($P_p > 2$), iako još uvijek ima prostora za poboljšanje procesa jer je $P_p < C_p$ (2,54), slika 41.



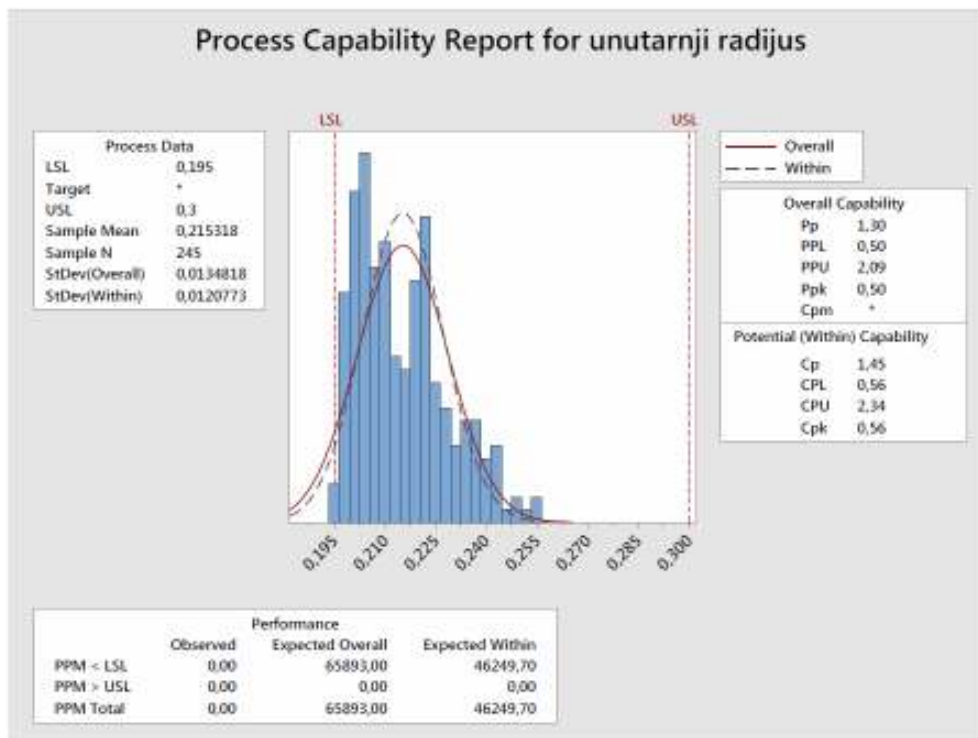
Slika 42. Procjena sposobnosti procesa za unutarnji kut

Procjena sposobnosti za vanjski kut prikazuje gotovo identičan slučaj kao i kod vanjskog kuta. Grafički prikaz također prikazuje centriran proces i stvarnom sposobnosti procesa $P_p = 2,12$. Iako još uvijek ima prostora za poboljšanje sposobnosti procesa $P_p < C_p (2,36)$, za to nema potrebe jer je proces dovoljno sposoban, slika 42.




Slika 43. Procjena sposobnosti procesa za vanjski radijus

Grafički prikaz prikazuje proces pomaknut u lijevo prema donjoj granici (LSL). Ne smije se donositi prerani zaključak s obzirom na grafički prikaz, jer je potrebno napomenuti da je materijalno i fizikalno nemoguće da rezni alat, koji je odgovoran za strojnu obradu vanjskog radijusa, napravi manji radijus od donje granice (LSL). S vremenom obrade troši se rezni alat zbog čega se povećava zakrivljenost vrha rezne oštrice tako da vanjski radijus može biti jedino veći. Stvarna sposobnost procesa iznosi $P_p = 1,28$ ($P_p > 1$), prema čemu se može zaključiti da je proces sposoban. Međutim potencijalna sposobnost procesa iznosi $C_p = 1,44$, odnosno $P_p < C_p$ što znači da ima prostora za poboljšavanje sposobnosti procesa, slika 43.



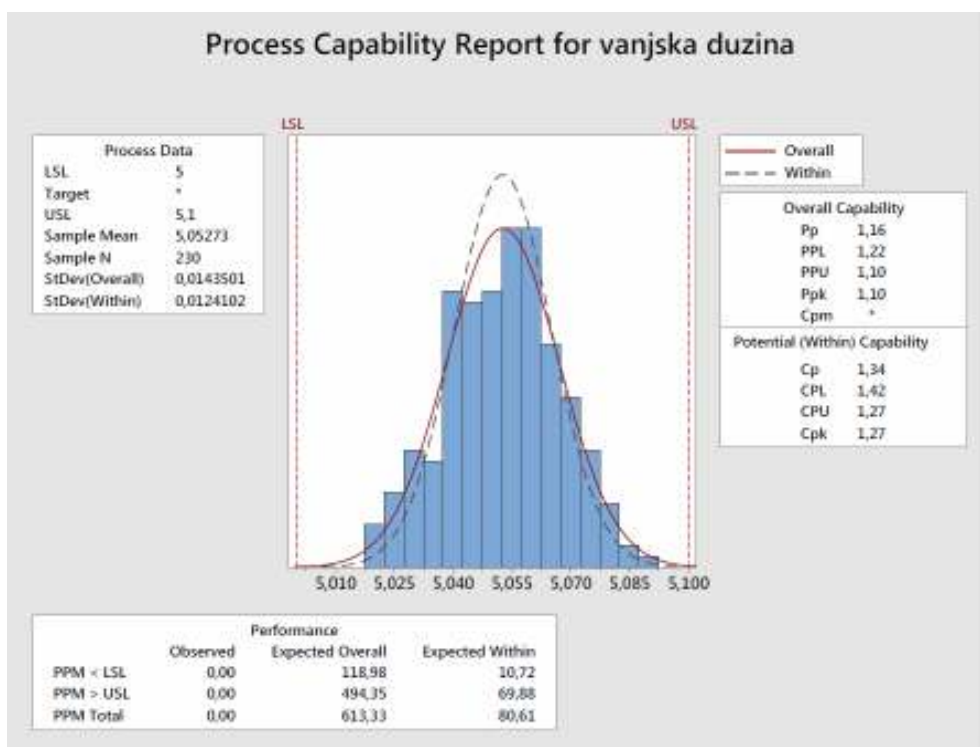
Slika 44. Procjena sposobnosti procesa za unutarnji radijus

S obzirom da se podaci ne ponašaju po normalnoj raspodjeli, slika 44., vrijednost indeksa stvarne sposobnosti procesa, $P_p = 1,30$, ne smije se promatrati kao relevantan. Potrebno je provesti Johnsonovu metodu transformacije ne-normalno distribuiranih podataka, te potom procijeniti sposobnost procesa s podacima koji se ponašaju po normalnoj distribuciji.




Slika 45. Procjena sposobnosti procesa za unutarnji radijus nakon transformacije podataka

Nakon transformacije ne-normalno distribuiranih podataka korištenjem Johnsonove metode transformacije u normalno distribuirane podatke koeficijent stvarne sposobnosti procesa iznosi $P_p = 1,75$, prema čemu se može zaključiti da je proces sposoban. S obzirom da je korištena procjena sposobnosti procesa nakon transformacije podataka korištenjem Johnsonove metode transformacije, Minitab ne može procijeniti varijacije unutar uzorka, te se ne mogu donijeti zaključci u kojoj je mjeri moguće unaprijediti proizvodni proces, slika 45.



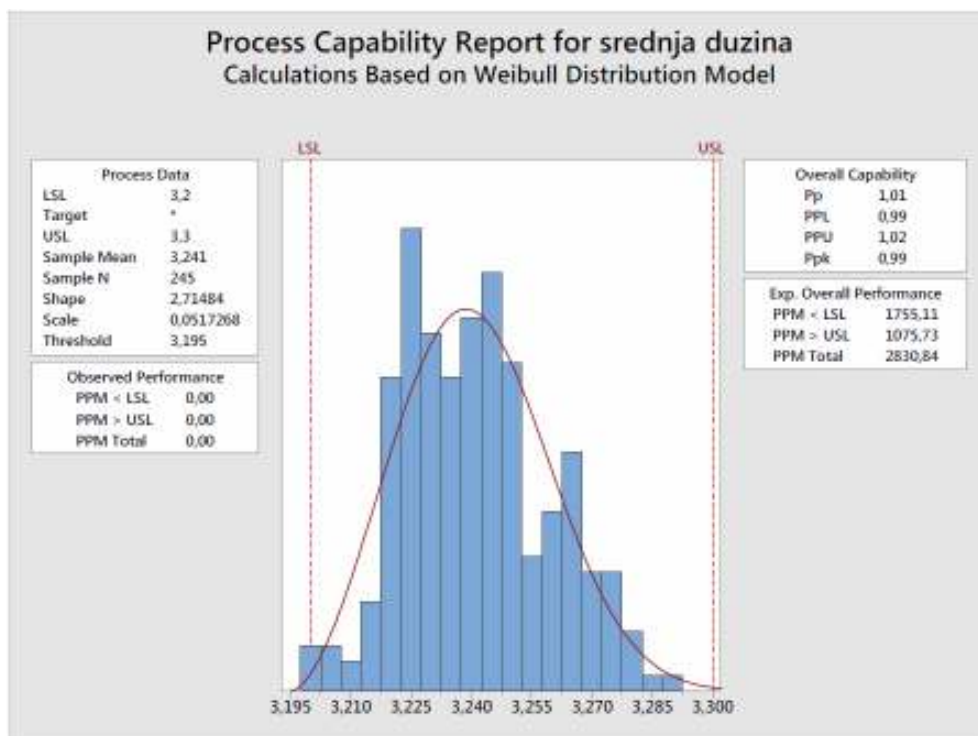
Slika 46. Procjena sposobnosti procesa za vanjsku dužinu

Grafički prikaz procjene sposobnosti za vanjski kut prikazuje centriran proces sa stvarnom sposobnosti procesa $P_p = 1,16$, prema čemu se može zaključiti da je proces sposoban, $P_p > 1$. Proces ima poprilično prostora za poboljšavanje, $P_p < C_p$ (1,34), no treba napomenuti kako se kotiranje svih dužina odvija proizvoljno, tako da i rezultate procjene sposobnosti za sve dužine treba uzeti s oprezom, te zbog toga nije moguće donijeti pravilan zaključak, slika 46.



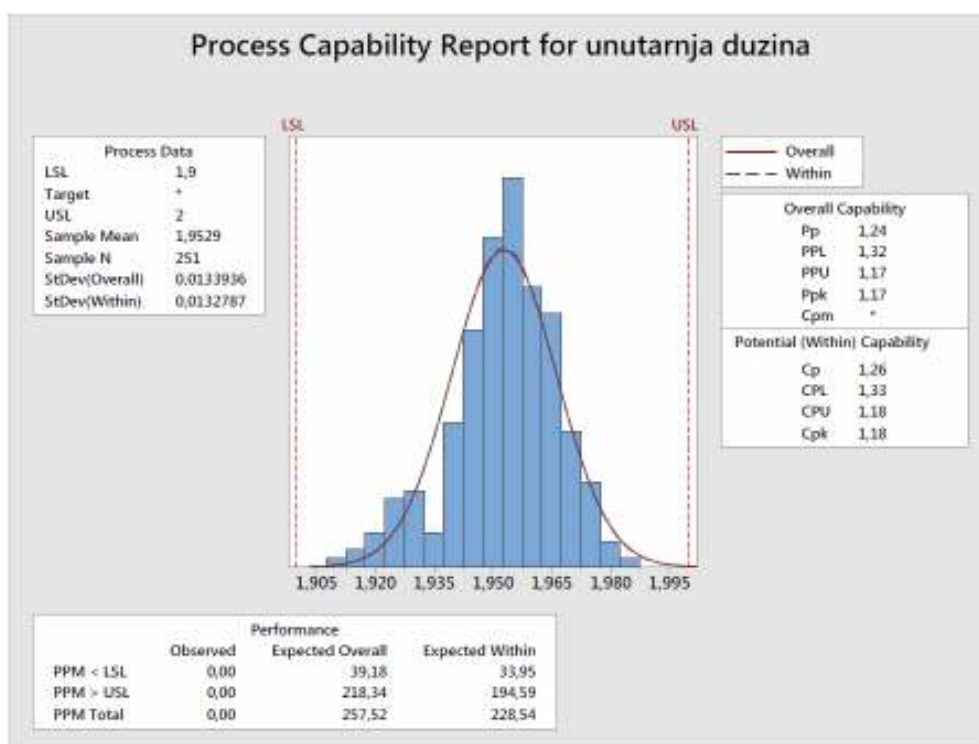
Slika 47. Procjena sposobnosti procesa za srednju dužinu

S obzirom da se podaci ponašaju po ne-normalnoj raspodjeli, potrebno je odabrati neki drugi distribucijski model za procjenu sposobnosti procesa, slika 47.



**Slika 48. Procjena sposobnosti procesa za srednju dužinu
uz Weibullov distribucijski model**

Kako podaci ne slijede normalnu distribuciju, odlučujemo se za procjenu sposobnosti procesa baziranu na Weibull-ovom modelu vjerojatnosti. Grafički prikaz pokazuje proces pomaknut u lijevo, a indeks stvarne sposobnosti procesa iznosi $P_p = 1,01$, što pokazuje da je proces na granici sposobnosti ($1 > P_p > 1,33$). S obzirom da su procjene sposobnosti zadovoljavajuće za odrez, unutarnji i vanjski kut, koje se mogu na neki način prozvati glavnim veličinama jer su te veličine najbolji pokazatelj kvalitete i zadovoljavajuće geometrije alata, ovaj rezultat za srednju dužinu može se zanemariti, slika 48.



Slika 49. Procjena sposobnosti procesa za unutarnju dužinu

Iako rezultati prikazuju gotovo centrirani proces sa sposobnim procesom, $P_p = 1,24$, koji ima jako malo prostora za poboljšavanje, $P_p = 1,24 < C_p = 1,26$, rezultat je također ovisi o proizvoljnom kotiranju dužina, te na temelju njih ne može se donijeti novi zaključak, slika 49.

Sveukupno gledano, ukoliko dolazi do pravovremene i redovite izmjene alata proces je sposoban. Na necentriranost pojedinih procesa moguće je djelovati korekcijom programa unutar numeričkog upravljanja tokarskog obradnog centra kako bi se dobile vrijednosti veličina u sredini tolerancijskog područja, uz upozorenje operaterima da obrate pažnju na dotrajalost reznog alata kako bi se pravovremeno dogodila njegova izmjena.

8. ZAKLJUČAK

Kontrolna karta je alat koji predstavlja sliku procesa. Tu sliku treba inženjerski promatrati, utvrditi anomalije, ocijeniti koje elemente, odnosno parametre, procesa treba pozornije pratiti i stalno tražiti i otklanjati uzroke statističkih pomaka procesa. Prije primjene statističkog postupka mjerne podatke treba vidjeti korištenjem odgovarajućih grafičkih prikaza. Tada se donosi odluka o svrsishodnosti primjene statističkih proračuna. Statistika treba potvrditi i kvantificirati očekivanje. Ona je igra velikih brojki. Stvaranje zaključaka temeljem malog broja podataka je uglavnom opasna filozofija. Kontrolnom kartom dobiva se uvid u varijabilnost podataka u vremenu, a histogramom normalnost podataka. Ukoliko raspodjela podataka nije normalna potrebno je tražiti moguće uzroke.

Slika procesa navodi inženjera kada je opravdano provesti određene statističke analize i to prvenstveno zbog kvantificiranja i potvrđivanja već donesenih zaključaka.

Upotreba kontrolnih karata pokazala je svoju prednost u stvarnom proizvodnom procesu tvrtke Štefan koja prethodno nije upotrebljavala kontrolne karte.

Kontrolnim kartama je utvrđeno da je proizvodni proces za svaku veličinu pod kontrolom, tako da je bilo moguće napraviti procjenu sposobnosti proizvodnog procesa. Potrebno je istaknuti da se cjelokupan proizvodni proces mogao pratiti preko tri veličine, a to su odrez, vanjski i unutarnji kut. Ukoliko su te tri veličine pod kontrolom, tada će i ostale veličine također biti pod kontrolom. Procjenom sposobnosti procesa za sve veličine utvrđeno je da nema potrebe za unapređivanjem proizvodnog sustava, potrebno je samo voditi računa o trošenju i pravovremenoj izmjeni alata.


Ovaj rad će biti iskorišten kao podloga za postepeno uvođenje kontrolnih karata u cjelokupan proizvodni proces navedene tvrtke, koja će navedeni model kontrole kvalitete nastaviti koristiti. S obzirom na dobre poslovne rezultate koji se postižu u suradnji s partnerima iz Njemačke, dobiveni rezultati su očekivani, te potvrđuju da se radi o veoma sposobnom procesu koji zadovoljava najmodernije zahtjeve koji se u današnje doba zahtjeva od proizvođača.

LITERATURA

- [1] V. Mudronja; Kontrolna karta-slika procesa; http://issuu.com/svijet-kvalitete.com/docs/kontrolna_karta_slika_procesa pristup 27-4-2015
- [2] KK_2014.pdf; predavanja iz kolegija Kontrola kvalitete
- [3] Kontrolne karte.pdf; predavanja iz kolegija Kontrola kvalitete
- [4] Normal distribution; https://en.wikipedia.org/wiki/Normal_distribution pristup 02-7-2015
- [5] Minitab 17; Minitab help; Nonnormal; Perform Capability Analysis
- [6] Parker Hannafin Catalog;
<http://www.parker.com/literature/Tube%20Fittings%20Division/EO%20and%20EO-2%20Metric%20Bite%20Type%20Fittings.pdf> pristup 8-6-2015
- [7] Mitutoyo: CBH-400, Contracer, User's Manual, MANUAL No. 4555, SERIES No. 218
- [8] Douglas C. Montgomery; Statistical Quality Control; 2012
- [9] Amitava Mitra; Fundamentals of Quality Control and Improvement; 2012

PRILOZI

- I. CD-R disc
- II. Tehnička dokumentacija



Ergebnisliste

Merkmal	Meßwert	Merkmal	Meßwert
Linie(Bereich)<Linie_2>		Punkt<Punkt_3>	
Neigung	-9,927°	X-Koord	-3,215mm
Linie(Bereich)<Linie_4>		Schnittpunkt (Linie/Linie)<Punkt_4>	
Neigung	8,436°	X-Koord	-1,928mm
Linie(Bereich)<Linie_13>		Kreis (Bereich)<R1>	
Neigung	45,019°	Radius	R 0,247mm
Linie(Bereich)<Linie_16>		Kreis (Bereich)<R2>	
Neigung	-10,268°	Radius	R 0,217mm
Punkt<Punkt_1>		Kreis (Bereich)<R3>	
X-Koord	-5,035mm	Radius	R 0,533mm
Punkt<Punkt_2>		Kreis (Bereich)<R4>	
X-Koord	-1,973mm	Radius	R 0,255mm

Messbedingungen

Meßgerät	CBH-400	Kommentar
Messlänge	100,0000mm	
Messpunktabstand	0,0100mm	
Messgeschwindigkeit	0,2000mm/s	
X-Vergrößerung	20	
Z-Vergrößerung	20	
Vibratorfunktion	aus	
Z-Faktor	1,000000	
Geradheitskompensation	aus	
Radiuskompensation	0,0264mm	
Abdruckmessung	aus	
Teilename	150417-pdr12LS-2	
Name 2		
Prüfer	Stefan	
Datum	17.4.2015 10:37:41	
Änderungsdatum	17.4.2015 10:43:02	
Geändert von	Stefan	
ÄnderungsNr.	1	

<i>redni broj</i>	<i>odrez</i>	<i>vanjski kut</i>	<i>unutarnji kut</i>	<i>vanjski radijus</i>	<i>unutarnji radijus</i>	<i>vanjska dužina</i>	<i>srednja dužina</i>	<i>unutarnja dužina</i>	<i>smjena</i>	<i>dan</i>	<i>broj dana</i>
1	44,818	9,978	8,408	0,24	0,211	5,044	3,223	1,953	1	13.04.2015	1
2	44,919	10,112	8,541	0,299	0,238	5,054	3,214	1,957	1	13.04.2015	1
3	44,893	10,076	8,42	0,286	0,251	5,056	3,221	1,949	1	13.04.2015	1
4	45,046	10,047	8,448	0,202	0,209	5,006	3,202	1,95	1	13.04.2015	1
5	44,805	10,16	8,314	0,262	0,208	5,078	3,29	1,968	1	13.04.2015	1
6	45,117	9,898	8,47	0,238	0,23	5,071	3,246	1,923	1	13.04.2015	1
7	44,918	10,003	8,431	0,236	0,237	5,07	3,221	1,945	2	13.04.2015	1
8	44,939	9,972	8,525	0,269	0,207	5,067	3,262	1,954	2	13.04.2015	1
9	45,045	9,985	8,536	0,229	0,219	5,043	3,245	1,947	2	13.04.2015	1
10	44,816	10,061	8,586	0,286	0,228	5,062	3,248	1,957	2	13.04.2015	1
11	44,946	10,055	8,662	0,238	0,202	5,06	3,265	1,944	2	13.04.2015	1
12	44,997	9,883	8,626	0,279	0,221	5,073	3,25	1,972	2	13.04.2015	1
13	44,913	10,033	8,581	0,254	0,255	5,017	3,203	1,962	3	14.04.2015	2
14	44,985	10,082	8,492	0,256	0,244	5,021	3,216	1,952	3	14.04.2015	2
15	45,042	9,916	8,52	0,2	0,22	5,019	3,218	1,948	3	14.04.2015	2
16	44,961	9,857	8,433	0,223	0,218	5,019	3,203	1,927	3	14.04.2015	2
17	44,858	10,072	8,472	0,276	0,223	5,022	3,213	1,958	3	14.04.2015	2
18	45,008	10,088	8,274	0,266	0,22	5,015	3,205	1,953	3	14.04.2015	2
19	45,021	10,02	8,542	0,241	0,204	5,029	3,206	1,955	1	14.04.2015	2
20	45,081	10,099	8,653	0,256	0,218	5,04	3,226	1,98	1	14.04.2015	2
21	44,842	9,971	8,587	0,241	0,213	5,034	3,2	1,961	1	14.04.2015	2
22	44,903	10,187	8,579	0,25	0,277	5,034	3,217	1,937	1	14.04.2015	2
23	44,839	10,038	8,441	0,202	0,199	5,023	3,205	1,928	1	14.04.2015	2
24	44,974	10,284	8,637	0,226	0,217	5,024	3,204	1,967	1	14.04.2015	2
25	44,979	10,115	8,582	0,286	0,218	5,031	3,224	1,975	2	14.04.2015	2
26	44,93	10,04	8,651	0,244	0,207	5,062	3,211	1,971	2	14.04.2015	2
27	45,099	10,082	8,457	0,326	0,221	5,043	3,202	1,961	2	14.04.2015	2
28	44,806	10,074	8,552	0,281	0,21	5,058	3,243	1,946	2	14.04.2015	2
29	44,847	10,227	8,492	0,276	0,205	5,062	3,255	1,958	2	14.04.2015	2
30	44,846	10,04	8,463	0,287	0,208	5,042	3,262	1,951	2	14.04.2015	2
31	44,809	9,947	8,511	0,296	0,226	5,056	3,214	1,948	3	15.04.2015	3
32	44,844	10,186	8,392	0,259	0,24	5,043	3,218	1,922	3	15.04.2015	3
33	44,935	10,187	8,588	0,275	0,281	5,058	3,218	1,916	3	15.04.2015	3
34	44,798	10,014	8,576	0,22	0,205	5,042	3,255	1,958	3	15.04.2015	3
35	44,917	9,99	8,363	0,219	0,213	5,04	3,216	1,977	3	15.04.2015	3
36	44,894	10,024	8,581	0,237	0,215	5,031	3,223	1,938	3	15.04.2015	3
37	44,979	10,036	8,433	0,221	0,221	5,046	3,221	1,959	1	15.04.2015	3
38	44,919	10,003	8,587	0,246	0,21	5,047	3,223	1,978	1	15.04.2015	3
39	44,886	9,976	8,551	0,215	0,204	5,025	3,224	1,949	1	15.04.2015	3
40	44,962	9,982	8,572	0,203	0,204	5,039	3,205	1,966	1	15.04.2015	3
41	45,094	9,915	8,533	0,224	0,212	5,039	3,2	1,96	1	15.04.2015	3
42	44,928	9,837	8,473	0,28	0,22	5,045	3,203	1,963	1	15.04.2015	3
43	44,918	10,012	8,456	0,227	0,217	5,041	3,223	1,91	2	15.04.2015	3
44	45,072	10,074	8,509	0,236	0,214	5,049	3,247	1,941	2	15.04.2015	3
45	44,94	9,891	8,614	0,267	0,203	5,048	3,243	1,957	2	15.04.2015	3
46	44,97	10,021	8,523	0,247	0,219	5,032	3,222	1,932	2	15.04.2015	3
47	44,907	10,188	8,527	0,281	0,246	5,02	3,23	1,955	2	15.04.2015	3
48	44,935	10,184	8,533	0,267	0,242	5,038	3,246	1,952	2	15.04.2015	3

<i>redni broj</i>	<i>odrez</i>	<i>vanjski kut</i>	<i>unutarnji kut</i>	<i>vanjski radijus</i>	<i>unutarnji radijus</i>	<i>vanjska dužina</i>	<i>srednja dužina</i>	<i>unutarnja dužina</i>	<i>smjena</i>	<i>dan</i>	<i>broj dana</i>
49	44,838	10,082	8,423	0,296	0,225	5,059	3,266	1,95	3	16.04.2015	4
50	44,866	10,095	8,544	0,293	0,208	5,047	3,241	1,971	3	16.04.2015	4
51	44,988	10,126	8,681	0,276	0,213	5,061	3,245	1,968	3	16.04.2015	4
52	44,884	9,963	8,542	0,274	0,204	5,037	3,273	1,977	3	16.04.2015	4
53	44,864	10,096	8,496	0,252	0,202	5,061	3,279	1,97	3	16.04.2015	4
54	44,929	9,981	8,482	0,227	0,213	5,047	3,249	1,958	3	16.04.2015	4
55	45,019	10,104	8,685	0,242	0,221	5,055	3,234	1,961	1	16.04.2015	4
56	44,975	10,135	8,496	0,242	0,24	5,079	3,265	1,959	1	16.04.2015	4
57	45,132	9,966	8,424	0,271	0,208	5,075	3,24	1,973	1	16.04.2015	4
58	45,038	10,189	8,396	0,225	0,203	5,048	3,231	1,97	1	16.04.2015	4
59	45,092	9,93	8,426	0,219	0,228	5,045	3,227	1,963	1	16.04.2015	4
60	44,921	9,834	8,407	0,22	0,224	5,037	3,236	1,946	1	16.04.2015	4
61	44,857	10,055	8,459	0,23	0,231	5,042	3,223	1,949	2	16.04.2015	4
62	44,984	10,035	8,308	0,226	0,234	5,026	3,274	1,949	2	16.04.2015	4
63	45,012	10,017	8,245	0,21	0,205	5,025	3,224	1,941	2	16.04.2015	4
64	45,08	9,923	8,466	0,217	0,268	5,059	3,223	1,933	2	16.04.2015	4
65	44,932	9,778	8,483	0,226	0,264	5,036	3,252	1,987	2	16.04.2015	4
66	44,954	9,984	8,571	0,216	0,22	5,021	3,221	1,949	2	16.04.2015	4
67	45,016	9,945	8,414	0,238	0,221	5,065	3,248	1,951	3	17.04.2015	5
68	45,142	10,038	8,154	0,243	0,222	5,057	3,265	1,95	3	17.04.2015	5
69	45,079	10,055	8,457	0,247	0,218	5,058	3,246	1,963	3	17.04.2015	5
70	44,952	9,971	8,431	0,246	0,242	5,069	3,247	1,958	3	17.04.2015	5
71	45,029	9,94	8,438	0,259	0,216	5,053	3,223	1,957	3	17.04.2015	5
72	44,932	9,973	8,089	0,233	0,241	5,059	3,241	1,953	3	17.04.2015	5
73	44,926	9,907	8,559	0,227	0,211	5,045	3,251	1,959	1	17.04.2015	5
74	45,077	9,853	8,333	0,209	0,235	5,061	3,239	1,951	1	17.04.2015	5
75	44,972	9,924	8,339	0,219	0,254	5,056	3,211	1,962	1	17.04.2015	5
76	44,828	9,848	8,594	0,273	0,199	5,046	3,233	1,955	1	17.04.2015	5
77	45,025	9,961	8,484	0,232	0,209	5,037	3,235	1,957	1	17.04.2015	5
78	45,096	9,936	8,376	0,218	0,2	5,034	3,223	1,956	1	17.04.2015	5
79	44,983	10,007	8,46	0,202	0,202	5,032	3,241	1,965	2	17.04.2015	5
80	44,875	9,994	8,374	0,297	0,204	5,053	3,244	1,947	2	17.04.2015	5
81	44,81	9,826	8,535	0,208	0,204	5,051	3,282	1,977	2	17.04.2015	5
82	45,097	9,919	8,394	0,245	0,201	5,069	3,266	1,966	2	17.04.2015	5
83	45,054	9,958	8,497	0,212	0,201	5,068	3,22	1,98	2	17.04.2015	5
84	45,007	9,835	8,43	0,222	0,207	5,052	3,223	1,95	2	17.04.2015	5
85	45,063	10,007	8,327	0,242	0,221	5,086	3,244	1,955	3	18.04.2015	6
86	44,957	9,929	8,406	0,249	0,206	5,076	3,225	1,968	3	18.04.2015	6
87	44,827	10,048	8,506	0,234	0,203	5,089	3,223	1,955	3	18.04.2015	6
88	45,013	9,937	8,411	0,253	0,203	5,073	3,277	1,953	3	18.04.2015	6
89	44,981	9,89	8,403	0,28	0,198	5,075	3,242	1,966	3	18.04.2015	6
90	45,005	9,917	8,543	0,264	0,208	5,065	3,247	1,948	3	18.04.2015	6
91	45,017	9,913	8,426	0,246	0,207	5,077	3,246	1,933	1	18.04.2015	6
92	45,01	9,892	8,418	0,233	0,202	5,074	3,264	1,949	1	18.04.2015	6
93	44,994	9,992	8,354	0,245	0,203	5,062	3,261	1,955	1	18.04.2015	6
94	44,898	9,946	8,278	0,256	0,197	5,074	3,251	1,948	1	18.04.2015	6
95	45,01	9,854	8,352	0,21	0,195	5,081	3,267	1,948	1	18.04.2015	6
96	45,008	9,883	8,469	0,22	0,206	5,074	3,257	1,956	1	18.04.2015	6

<i>redni broj</i>	<i>odrez</i>	<i>vanjski kut</i>	<i>unutarnji kut</i>	<i>vanjski radijus</i>	<i>unutarnji radijus</i>	<i>vanjska dužina</i>	<i>srednja dužina</i>	<i>unutarnja dužina</i>	<i>smjena</i>	<i>dan</i>	<i>broj dana</i>
97	44,844	9,855	8,422	0,341	0,207	5,088	3,27	1,965	2	18.04.2015	6
98	44,912	9,902	8,452	0,26	0,21	5,072	3,232	1,966	2	18.04.2015	6
99	44,876	9,996	8,278	0,368	0,197	5,088	3,277	1,927	2	18.04.2015	6
100	44,84	9,968	8,469	0,276	0,2	5,074	3,272	1,957	2	18.04.2015	6
101	44,989	9,904	8,2	0,215	0,205	5,069	3,265	1,943	2	18.04.2015	6
102	44,882	10,056	8,505	0,265	0,201	5,077	3,281	1,95	2	18.04.2015	6
103	44,944	10,082	8,831	0,247	0,205	5,068	3,248	1,951	3	20.04.2015	7
104	44,978	9,935	8,419	0,301	0,234	5,084	3,265	1,94	3	20.04.2015	7
105	44,94	9,845	8,561	0,275	0,219	5,086	3,262	1,957	3	20.04.2015	7
106	45	9,969	8,397	0,273	0,201	5,068	3,248	1,961	3	20.04.2015	7
107	45,014	10,172	8,552	0,286	0,198	5,068	3,268	1,94	3	20.04.2015	7
108	44,863	10,105	8,402	0,266	0,199	5,06	3,266	1,949	3	20.04.2015	7
109	44,967	9,912	8,389	0,299	0,227	5,061	3,24	1,947	1	20.04.2015	7
110	44,977	10,084	8,314	0,294	0,238	5,042	3,249	1,961	1	20.04.2015	7
111	44,928	9,995	8,316	0,29	0,214	5,061	3,252	1,958	1	20.04.2015	7
112	44,938	10,058	8,498	0,358	0,203	5,077	3,275	1,938	1	20.04.2015	7
113	44,912	9,859	8,575	0,301	0,209	5,082	3,282	1,956	1	20.04.2015	7
114	45,046	10,069	8,451	0,333	0,201	5,054	3,245	1,943	1	20.04.2015	7
115	44,903	9,851	8,351	0,286	0,205	5,054	3,223	1,942	2	20.04.2015	7
116	44,929	9,903	8,573	0,261	0,208	5,073	3,262	1,958	2	20.04.2015	7
117	44,844	10,031	8,348	0,268	0,213	5,06	3,269	1,944	2	20.04.2015	7
118	45,008	9,943	8,486	0,278	0,225	5,073	3,255	1,945	2	20.04.2015	7
119	44,836	9,974	8,597	0,283	0,211	5,065	3,262	1,958	2	20.04.2015	7
120	44,821	9,861	8,418	0,274	0,197	5,053	3,246	1,958	2	20.04.2015	7
121	45,143	9,925	8,574	0,234	0,2	5,045	3,249	1,952	3	21.04.2015	8
122	44,932	9,838	8,327	0,29	0,205	5,042	3,244	1,967	3	21.04.2015	8
123	44,902	9,885	8,363	0,286	0,216	5,054	3,251	1,952	3	21.04.2015	8
124	44,793	10,05	8,303	0,26	0,226	5,053	3,238	1,964	3	21.04.2015	8
125	45,033	10,06	8,382	0,262	0,197	5,055	3,255	1,95	3	21.04.2015	8
126	45,186	10,183	8,485	0,268	0,236	5,051	3,269	1,948	3	21.04.2015	8
127	44,906	10,063	8,248	0,271	0,204	5,057	3,289	1,946	1	21.04.2015	8
128	45,17	10,07	8,22	0,292	0,22	5,061	3,243	1,939	1	21.04.2015	8
129	44,852	10,154	8,162	0,275	0,206	5,056	3,243	1,956	1	21.04.2015	8
130	44,834	10,017	8,452	0,242	0,226	5,063	3,223	1,968	1	21.04.2015	8
131	44,846	9,974	8,175	0,308	0,223	5,067	3,266	1,966	1	21.04.2015	8
132	44,758	10	8,216	0,267	0,221	5,046	3,24	1,946	1	21.04.2015	8
133	44,981	9,986	8,22	0,26	0,21	5,055	3,248	1,944	2	21.04.2015	8
134	44,839	9,944	8,149	0,272	0,225	5,05	3,23	1,949	2	21.04.2015	8
135	45,03	10,154	8,482	0,248	0,21	5,023	3,268	1,944	2	21.04.2015	8
136	44,967	10,069	8,573	0,208	0,22	5,067	3,239	1,958	2	21.04.2015	8
137	45,056	9,925	8,626	0,212	0,216	5,048	3,248	1,95	2	21.04.2015	8
138	44,977	9,978	8,5	0,247	0,219	5,058	3,264	1,949	2	21.04.2015	8
139	44,971	10,117	8,498	0,222	0,197	5,054	3,22	1,931	3	22.04.2015	9
140	44,998	10,042	8,505	0,224	0,22	5,059	3,243	1,944	3	22.04.2015	9
141	45,084	9,993	8,532	0,248	0,21	5,048	3,234	1,942	3	22.04.2015	9
142	44,909	10,026	8,484	0,211	0,217	5,056	3,262	1,942	3	22.04.2015	9
143	44,989	9,992	8,508	0,226	0,219	5,044	3,225	1,945	3	22.04.2015	9
144	45,007	9,988	8,592	0,219	0,224	5,068	3,251	1,947	3	22.04.2015	9

<i>redni broj</i>	<i>odrez</i>	<i>vanjski kut</i>	<i>unutarnji kut</i>	<i>vanjski radijus</i>	<i>unutarnji radijus</i>	<i>vanjska dužina</i>	<i>srednja dužina</i>	<i>unutarnja dužina</i>	<i>smjena</i>	<i>dan</i>	<i>broj dana</i>
145	44,915	9,945	8,658	0,225	0,223	5,049	3,263	1,947	1	22.04.2015	9
146	44,961	10,058	8,663	0,247	0,224	5,044	3,277	1,965	1	22.04.2015	9
147	44,996	9,962	8,664	0,251	0,227	5,065	3,26	1,97	1	22.04.2015	9
148	44,919	10,021	8,464	0,253	0,235	5,046	3,274	1,94	1	22.04.2015	9
149	45,015	10,101	8,523	0,248	0,229	5,044	3,264	1,967	1	22.04.2015	9
150	45,078	10,088	8,65	0,263	0,23	5,045	3,286	1,948	1	22.04.2015	9
151	45,056	9,866	8,717	0,254	0,214	5,041	3,256	1,941	2	22.04.2015	9
152	44,899	10,04	8,429	0,237	0,224	5,03	3,223	1,964	2	22.04.2015	9
153	44,905	9,964	8,428	0,235	0,23	5,028	3,223	1,964	2	22.04.2015	9
154	44,935	10,037	8,464	0,255	0,223	5,054	3,228	1,932	2	22.04.2015	9
155	44,91	9,993	8,552	0,224	0,215	5,04	3,22	1,948	2	22.04.2015	9
156	45,026	10,143	8,589	0,23	0,214	5,039	3,232	1,944	2	22.04.2015	9
157	44,929	9,974	8,523	0,235	0,223	5,055	3,236	1,923	3	23.04.2015	10
158	44,94	9,96	8,516	0,237	0,225	5,06	3,239	1,956	3	23.04.2015	10
159	44,887	10,093	8,482	0,247	0,201	5,072	3,242	1,923	3	23.04.2015	10
160	44,945	10,039	8,573	0,253	0,23	5,047	3,226	1,955	3	23.04.2015	10
161	44,864	9,941	8,615	0,23	0,222	5,052	3,231	1,953	3	23.04.2015	10
162	45,137	10,003	8,448	0,249	0,229	5,05	3,243	1,968	3	23.04.2015	10
163	45,055	9,993	8,574	0,272	0,221	5,063	3,221	1,96	1	23.04.2015	10
164	44,835	9,943	8,563	0,253	0,221	5,065	3,251	1,954	1	23.04.2015	10
165	44,983	10,039	8,44	0,243	0,222	5,06	3,241	1,953	1	23.04.2015	10
166	45,095	9,936	8,565	0,242	0,238	5,048	3,244	1,955	1	23.04.2015	10
167	44,882	10,073	8,586	0,234	0,229	5,048	3,221	1,965	1	23.04.2015	10
168	44,902	10,024	8,538	0,267	0,24	5,059	3,259	1,951	1	23.04.2015	10
169	44,859	9,933	8,478	0,222	0,236	5,06	3,262	1,96	2	23.04.2015	10
170	45,051	9,95	8,41	0,294	0,222	5,051	3,228	1,956	2	23.04.2015	10
171	45,017	10,092	8,583	0,318	0,233	5,028	3,231	1,925	2	23.04.2015	10
172	44,911	10,045	8,49	0,246	0,243	5,053	3,267	1,968	2	23.04.2015	10
173	45,082	9,969	8,471	0,254	0,237	5,045	3,245	1,969	2	23.04.2015	10
174	44,957	10,007	8,553	0,297	0,209	5,041	3,23	1,919	2	23.04.2015	10
175	44,93	9,915	8,553	0,263	0,243	5,054	3,257	1,961	3	24.04.2015	11
176	45,03	9,965	8,436	0,242	0,234	5,056	3,221	1,976	3	24.04.2015	11
177	44,962	9,93	8,512	0,262	0,238	5,066	3,228	1,955	3	24.04.2015	11
178	45,132	10,034	8,587	0,244	0,248	5,054	3,223	1,962	3	24.04.2015	11
179	45	9,888	8,484	0,267	0,197	5,051	3,241	1,928	3	24.04.2015	11
180	44,913	9,971	8,472	0,243	0,202	5,049	3,233	1,945	3	24.04.2015	11
181	44,934	9,848	8,555	0,234	0,242	5,064	3,221	1,912	1	24.04.2015	11
182	45,025	10,064	8,49	0,253	0,227	5,066	3,233	1,929	1	24.04.2015	11
183	44,992	9,875	8,601	0,233	0,262	5,062	3,232	1,966	1	24.04.2015	11
184	45,032	10,012	8,493	0,281	0,261	5,038	3,238	1,963	1	25.04.2015	12
185	45,001	9,967	8,571	0,276	0,262	5,05	3,229	1,964	1	25.04.2015	12
186	44,919	10,021	8,581	0,233	0,233	5,041	3,221	1,957	1	25.04.2015	12
187	44,995	10,018	8,497	0,294	0,206	5,08	3,226	1,958	2	25.04.2015	12
188	44,938	9,961	8,515	0,291	0,211	5,071	3,246	1,957	2	25.04.2015	12
189	45,026	9,94	8,561	0,3	0,201	5,077	3,244	1,94	2	25.04.2015	12
190	44,81	10,104	8,474	0,321	0,209	5,052	3,238	1,918	2	25.04.2015	12
191	44,949	9,951	8,584	0,288	0,215	5,088	3,256	1,95	2	25.04.2015	12
192	45,085	9,996	8,537	0,294	0,211	5,072	3,267	1,94	2	25.04.2015	12

<i>redni broj</i>	<i>odrez</i>	<i>vanjski kut</i>	<i>unutarnji kut</i>	<i>vanjski radijus</i>	<i>unutarnji radijus</i>	<i>vanjska dužina</i>	<i>srednja dužina</i>	<i>unutarnja dužina</i>	<i>smjena</i>	<i>dan</i>	<i>broj dana</i>
193	45,015	9,931	8,581	0,214	0,204	5,066	3,233	1,946	1	27.04.2015	13
194	45,002	10,027	8,436	0,278	0,205	5,055	3,23	1,959	1	27.04.2015	13
195	45,108	9,962	8,551	0,253	0,216	5,055	3,248	1,931	1	27.04.2015	13
196	44,994	9,972	8,529	0,266	0,204	5,035	3,232	1,956	1	27.04.2015	13
197	44,954	10,004	8,516	0,225	0,205	5,028	3,237	1,976	1	27.04.2015	13
198	44,956	9,967	8,543	0,257	0,211	5,02	3,232	1,967	1	27.04.2015	13
199	45,014	10,009	8,493	0,241	0,208	5,038	3,25	1,955	2	27.04.2015	13
200	45,003	9,925	8,456	0,253	0,2	5,042	3,236	1,941	2	27.04.2015	13
201	45,076	9,988	8,501	0,263	0,204	5,074	3,236	1,952	2	27.04.2015	13
202	44,985	9,967	8,51	0,234	0,202	5,047	3,235	1,954	2	27.04.2015	13
203	44,972	10,024	8,491	0,249	0,202	5,054	3,237	1,957	2	27.04.2015	13
204	45,049	10,027	8,564	0,225	0,211	5,043	3,235	1,957	2	27.04.2015	13
205	44,998	10,013	8,578	0,257	0,212	5,059	3,236	1,968	1	28.04.2015	14
206	45,086	9,87	8,47	0,244	0,217	5,063	3,224	1,956	1	28.04.2015	14
207	44,918	9,948	8,504	0,278	0,212	5,061	3,275	1,963	1	28.04.2015	14
208	44,93	9,963	8,586	0,236	0,202	5,026	3,222	1,963	1	28.04.2015	14
209	45,05	9,953	8,504	0,261	0,199	5,02	3,223	1,975	1	28.04.2015	14
210	45,012	9,956	8,585	0,208	0,204	5,06	3,228	1,915	1	28.04.2015	14
211	45,079	10,097	8,566	0,229	0,2	5,04	3,221	1,95	2	28.04.2015	14
212	45,079	9,983	8,488	0,246	0,204	5,039	3,231	1,947	2	28.04.2015	14
213	44,911	10,01	8,547	0,255	0,198	5,04	3,222	1,969	2	28.04.2015	14
214	44,979	10,004	8,51	0,238	0,201	5,041	3,237	1,971	2	28.04.2015	14
215	44,981	10,044	8,472	0,26	0,199	5,032	3,23	1,962	2	28.04.2015	14
216	44,915	9,93	8,427	0,287	0,197	5,037	3,234	1,926	2	28.04.2015	14
217	45,026	10,022	8,533	0,27	0,201	5,076	3,262	1,963	1	29.04.2015	15
218	44,941	9,977	8,535	0,254	0,2	5,063	3,238	1,964	1	29.04.2015	15
219	45,025	9,945	8,5	0,245	0,196	5,057	3,249	1,957	1	29.04.2015	15
220	45,002	10,002	8,578	0,249	0,207	5,063	3,242	1,959	1	29.04.2015	15
221	44,956	9,976	8,525	0,276	0,201	5,032	3,234	1,945	1	29.04.2015	15
222	45,025	10,024	8,569	0,241	0,208	5,046	3,231	1,957	1	29.04.2015	15
223	45,103	9,987	8,516	0,299	0,207	5,073	3,246	1,977	2	29.04.2015	15
224	44,986	9,993	8,47	0,293	0,198	5,078	3,252	1,951	2	29.04.2015	15
225	44,91	9,982	8,505	0,295	0,196	5,072	3,229	1,973	2	29.04.2015	15
226	45,021	9,996	8,422	0,314	0,23	5,069	3,224	1,945	2	29.04.2015	15
227	45,066	10,057	8,483	0,301	0,239	5,077	3,24	1,947	2	29.04.2015	15
228	44,947	10,055	8,422	0,291	0,249	5,056	3,241	1,945	2	29.04.2015	15
229	45,011	10,019	8,536	0,251	0,211	5,044	3,238	1,956	1	30.04.2015	16
230	45,001	10,022	8,631	0,263	0,21	5,038	3,236	1,938	1	30.04.2015	16
231	45,006	10,002	8,518	0,274	0,205	5,036	3,268	1,942	1	30.04.2015	16
232	44,948	9,987	8,567	0,284	0,216	5,064	3,271	1,955	1	30.04.2015	16
233	44,967	9,968	8,489	0,213	0,221	5,055	3,254	1,967	1	30.04.2015	16
234	45,002	9,964	8,503	0,242	0,214	5,059	3,243	1,936	1	30.04.2015	16
235	44,893	9,997	8,511	0,236	0,223	5,049	3,251	1,944	2	30.04.2015	16
236	44,958	9,963	8,578	0,255	0,219	5,05	3,242	1,951	2	30.04.2015	16
237	44,997	9,981	8,493	0,276	0,199	5,061	3,223	1,958	2	30.04.2015	16
238	44,929	9,992	8,467	0,268	0,197	5,066	3,261	1,932	2	30.04.2015	16
239	44,899	9,937	8,477	0,245	0,202	5,057	3,246	1,928	2	30.04.2015	16
240	44,936	9,934	8,482	0,243	0,204	5,052	3,241	1,922	2	30.04.2015	16

<i>redni broj</i>	<i>odrez</i>	<i>vanjski kut</i>	<i>unutarnji kut</i>	<i>vanjski radijus</i>	<i>unutarnji radijus</i>	<i>vanjska dužina</i>	<i>srednja dužina</i>	<i>unutarnja dužina</i>	<i>smjena</i>	<i>dan</i>	<i>broj dana</i>
241	44,998	10,014	8,534	0,267	0,221	5,064	3,223	1,96	1	4.05.2015	17
242	44,946	9,998	8,551	0,286	0,227	5,041	3,228	1,951	1	4.05.2015	17
243	44,973	10,027	8,542	0,26	0,234	5,049	3,223	1,953	1	4.05.2015	17
244	45,013	10,054	8,512	0,262	0,223	5,062	3,22	1,963	1	4.05.2015	17
245	45,027	10,022	8,492	0,268	0,219	5,038	3,231	1,965	1	4.05.2015	17
246	45,005	9,944	8,486	0,271	0,22	5,05	3,236	1,954	1	4.05.2015	17
247	45,029	9,988	8,524	0,26	0,206	5,077	3,232	1,96	2	4.05.2015	17
248	45,094	9,897	8,563	0,275	0,211	5,08	3,242	1,926	2	4.05.2015	17
249	45,087	10,01	8,541	0,242	0,201	5,071	3,226	1,955	2	4.05.2015	17
250	44,978	10,023	8,446	0,308	0,223	5,049	3,239	1,964	2	4.05.2015	17
251	44,964	9,997	8,497	0,29	0,221	5,052	3,243	1,957	2	4.05.2015	17
252	44,993	9,887	8,438	0,292	0,21	5,066	3,221	1,959	2	4.05.2015	17